

UNIVERSIDAD AUTÓNOMA DE MADRID

ESCUELA POLITÉCNICA SUPERIOR



TRABAJO FIN DE MÁSTER

Estudio y Propuesta de Nuevos Métodos de Aprendizaje Automático para la Detección de Grupos de Edad en Niños a través de la Interacción con los Dispositivos Móviles

Máster Universitario en Investigación e Innovación en
Inteligencia Computacional y Sistemas Interactivos

Autor: Juan Carlos Ruiz García
Tutor: Rubén Tolosana Moranchel
Ponente: Julián Fierrez Aguilar

JUNIO 2021

ESTUDIO Y PROPUESTA DE NUEVOS MÉTODOS DE APRENDIZAJE AUTOMÁTICO PARA LA DETECCIÓN DE GRUPOS DE EDAD EN NIÑOS A TRAVÉS DE LA INTERACCIÓN CON LOS DISPOSITIVOS MÓVILES

Autor: Juan Carlos Ruiz García

Tutor: Rubén Tolosana Moranchel
Ponente: Julián Fierrez Aguilar



Biometrics and Data Pattern Analytics Lab

Departamento de Tecnología Electrónica y de las Comunicaciones

JUNIO 2021

Resumen

En los últimos años se ha incrementado en gran medida el uso de los dispositivos móviles por parte de los niños, desde *smartphones* y *tablets* a los más recientes *smartwatches*. Además, esto se ha visto potenciado debido al brote producido por el COVID-19 durante el pasado año 2020, época en la cual la educación tradicional ha tenido que ser sustituida temporalmente por la educación virtual (*e-Learning*). En la actualidad, hay estudios recientes en la literatura que demuestran el uso de dispositivos móviles por parte de niños desde edades muy tempranas. Los dispositivos móviles también se han estudiado como una forma de enseñar a los niños, en particular a través del uso de aplicaciones. Sin embargo, el análisis de la evolución cognitiva y motora del niño/a durante su proceso de crecimiento se sigue realizando a día de hoy de forma manual, por medio de métodos tradicionales restrictivos y poco fiables. Además de ello, las bases de datos disponibles en este campo de aplicación son escasas y poco adaptadas a los escenarios de la vida real.

Este Trabajo de Fin de Máster (TFM) pretende realizar un primer estudio y mejora en este campo de aplicación, analizando la forma en la que los niños interactúan con los dispositivos móviles desde edades tempranas. Para ello, y debido a la escasez de bases de datos públicas, un primer paso consiste en la captura de una nueva base de datos (ChildCIdb¹) en colaboración con el Colegio GSD Las Suertes en Madrid, contando con más de 400 niños con edades comprendidas entre los 18 meses y los 8 años. En este TFM se proporcionará todos los detalles relativos al diseño de la aplicación software y protocolo de captura de la base de datos. Además, como primera tarea dentro de este TFM se pretende analizar y proponer nuevos métodos de aprendizaje automático para la detección de grupos de edad en niños a través de la interacción con los dispositivos móviles. Los resultados obtenidos permitirán ampliar el conocimiento relativo a la evolución de los desarrollos cognitivos y motores en el proceso de crecimiento de los niños.

Palabras Clave

Interacción Niño-Ordenador, Visión por Ordenador, e-Health, e-Learning, ChildCIdb, Detección de la Edad

¹https://github.com/BiDALab/ChildCIdb_v1

Abstract

The use of mobile devices by children has increased greatly in recent years, from smartphones and tablets to the more recent smartwatches. Moreover, this has been enhanced due to the outbreak of COVID-19 during the past year 2020, a time when traditional education has been temporarily replaced by e-Learning. There are recent studies in the literature that demonstrate the use of mobile devices by children from a very young age. Mobile devices have also been studied as a way of teaching children, in particular through the use of apps. However, the analysis of children's cognitive and motor development during their growth process is still carried out manually, using traditional methods that are restrictive and unreliable. Furthermore, public databases in this field of application are scarce and poorly adapted to real-life scenarios.

This M.Sc. Thesis aims to carry out a first study in order to analyse the way in which children interact with mobile devices from an early age. To this end, and due to the scarcity of public databases, a first step consists of capturing a new database (ChildCIdb²) in collaboration with the GSD Las Suertes School in Madrid, with more than 400 children aged between 18 months and 8 years. Thesis provides all the details related to the design of the software application and the database acquisition protocol. In addition, as a first task within this research project, we also analyse and propose new machine learning methods for the detection of age groups in children through interaction with mobile devices. The results obtained will allow us to broaden our knowledge in the evolution of the cognitive and neuromotor process of the children along time.

Key words

Child-Computer Interaction, Computer Vision, e-Health, e-Learning, ChildCIdb, Age Detection

²https://github.com/BiDALab/ChildCIdb_v1

Agradecimientos

Inicialmente me gustaría agradecer este trabajo a mi tutor Rubén Tolosana. Gracias por tu paciencia, enseñanzas y sobre todo por la confianza que siempre has depositado en mí desde el primer día. Eres un ejemplo a seguir y un excelente tutor.

A mi pareja por estar a mi lado en todo momento, siendo mi apoyo diario e incondicional. Contigo los momentos malos no son tan malos y los buenos son muchísimo mejores.

A mi familia por ser el pilar fundamental sobre el que sostenerme. En especial a mis padres, ya que sin ellos nada de esto hubiera sido posible. Les debo, entre otras muchas cosas, la gran educación que me han dado. Si hoy estoy donde estoy es principalmente gracias a ellos.

A la Escuela Politécnica Superior de la Universidad Autónoma de Madrid por darme la oportunidad de poder formar parte de ella como estudiante y por el gran trato recibido de parte de todo su personal, desde el primero al último.

Índice general

Índice de Figuras	IX
Índice de Tablas	XI
1. Introducción	1
1.1. Motivación	1
1.2. Objetivos	1
1.3. Metodología y Plan de Trabajo	3
1.4. Estructura de la Memoria	4
2. Estado del Arte	5
2.1. Teoría de Piaget	5
2.2. Instrumento de Captura: Stylus vs Finger	6
2.3. Características Automáticas Útiles en el Análisis de la Interacción de los Niños con los Dispositivos Móviles	9
3. ChildCI	13
3.1. Base de Datos	13
3.1.1. Plan Anual de Captura	14
3.1.2. Protocolo de Captura	14
3.1.3. Fase 1 de Captura (ChildCIdb_v1)	14
3.1.4. Fase 2 de Captura (ChildCIdb_v2)	16
3.2. Aplicación Android	18
3.2.1. Mejoras de la Aplicación Software	21
4. Detección de Grupos de Edad: Método Propuesto	23
4.1. Características Globales Propuestas	24
4.1.1. Test 1: Tap and Reaction Time	24
4.1.2. Test 2: Drag and Drop	24
4.1.3. Test 3 y 4: Zoom-in y Zoom-out	26
4.1.4. Test 5: Spiral Test	26
4.1.5. Test 6: Drawing Test	28

4.2. Características Globales Adicionales	28
4.3. Técnicas de Machine Learning	31
4.3.1. Extracción de Características	31
4.3.2. Selección de Características	32
4.3.3. Clasificación	32
5. Experimentos y Resultados	35
5.1. Protocolo Experimental	35
5.2. Evaluación de los Resultados	36
5.2.1. Test 1: Tap and Reaction Time	36
5.2.2. Test 2: Drag and Drop	38
5.2.3. Test 3: Zoom-in	38
5.2.4. Test 4: Zoom-out	40
5.2.5. Test 5: Spiral Test	40
5.2.6. Test 6: Drawing Test	42
5.3. Combinación de los Métodos de Clasificación	44
6. Conclusiones y Trabajo Futuro	49
6.1. Conclusiones	49
6.2. Limitaciones y Trabajo Futuro	50
Glosario de acrónimos	51
Bibliografía	52

Índice de Figuras

2.1. Esquema de asimilación-acomodación según Piaget.	6
2.2. LDP: es el punto más alejado de la línea recta entre el punto de inicio y el punto de parada de la curva de deslizamiento.	10
3.1. Comparativa gráfica de las estadísticas obtenidas sobre el número de niños asociados a cada nivel educativo y la información sobre la cantidad de niños por nivel, el género y la lateralidad en las captaciones de las versiones primera y segunda de ChildCIdb.	17
3.2. Comparativa gráfica de las estadísticas obtenidas sobre el el estado anímico de los niños durante la captación de las versiones primera y segunda de ChildCIdb. NS/NC significa “no sabe/no contesta”.	17
3.3. Ejemplos de las diferentes interfaces diseñadas en ChildCI para cada prueba, antes y después de su ejecución, incluyendo el tiempo máximo establecido en cada una de ellas. Se consideran tres bloques principales de adquisición: <i>i)</i> emocional, <i>ii)</i> táctil y <i>iii)</i> <i>stylus</i>	19
3.4. Esquema de ejemplo de una adquisición simultanea realizada sobre diferentes entidades educativas en distintas fases de captura.	22
4.1. Desarrollo del “Test 1: Tap and Reaction Time”. A la izquierda, el test al comienzo. A la derecha, el test al finalizar.	25
4.2. Desarrollo del “Test 2: Drag and Drop”. A la izquierda, el test al comienzo. A la derecha, el test al finalizar.	25
4.3. Desarrollo del “Test 3 y 4: Zoom-in y Zoom-out”. A la izquierda, el “Test3: Zoom-in al comenzar y al terminar”. A la derecha, el “Test4: Zoom-out al comenzar y al terminar”.	26
4.4. Desarrollo del “Test 5: Spiral Test”. A la izquierda, el test al comienzo. A la derecha, el test al finalizar.	27
4.5. Desarrollo del “Test 6: Drawing Test”. A la izquierda, el test al comienzo. A la derecha, el test al finalizar.	28
5.1. Gráficos de las mejores características seleccionadas en la sección 5.2.1. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “ Tap and Reaction Time ” en el espacio 2D generado mediante UMAP (SFFS + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.	37

5.2.	Gráficos de las mejores características seleccionadas en la sección 5.2.2. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “ Drag and Drop ” en el espacio 2D generado mediante UMAP (SFFS + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.	37
5.3.	Gráficos de las mejores características seleccionadas en la sección 5.2.3. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “ Zoom-in ” en el espacio 2D generado mediante UMAP (GA + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.	39
5.4.	Gráficos de las mejores características seleccionadas en la sección 5.2.4. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “ Zoom-out ” en el espacio 2D generado mediante UMAP (GA + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.	39
5.5.	Gráficos de las mejores características seleccionadas en la sección 5.2.5. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “ Spiral Test ” en el espacio 2D generado mediante UMAP (SFFS + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.	41
5.6.	Gráficos de las mejores características seleccionadas en la sección 5.2.6. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “ Drawing Test ” en el espacio 2D generado mediante UMAP (SFFS + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.	41
5.7.	Ejemplos de “ Spiral Test ” y de “ Drawing Test ” realizados por tres grupos de edad de niños diferentes: (arriba) de 1 a 3 años, (en medio) de 3 a 6 años y (abajo) de 6 a 8 años.	43

Índice de Tablas

2.1. Comparación de diferentes estudios centrados en la interacción de los niños con los dispositivos móviles.	7
3.1. Estadísticas del conjunto de datos ChildCIdb_v1 sobre el número de niños asociados a cada nivel educativo y la información sobre el género y la lateralidad. . .	15
3.2. Estadísticas del análisis del estado emocional por nivel educativo para el Child-CIdb_v1. NS/NC significa "no sabe/no contesta".	15
3.3. Estadísticas del conjunto de datos ChildCIdb_v2 sobre el número de niños asociados a cada nivel educativo y la información sobre el género y la lateralidad. . .	18
3.4. Estadísticas del análisis del estado emocional por nivel educativo para el Child-CIdb_v2. NS/NC significa "no sabe/no contesta".	18
4.1. Tabla cuyos colores identifican el tipo de información que contiene cada una de las características de las tablas: 4.3, 4.5, 4.7, 4.10, 4.11, 4.12.	24
4.2. Valores capturados durante el desarrollo de la tarea de <i>tap</i> (Test 1: Tap and Reaction Time)	25
4.3. Conjunto de 5 características globales propuestas en este TFM para la tarea de tocar (Test 1: Tap and Reaction Time).	25
4.4. Valores capturados durante el desarrollo de la tarea de arrastrar soltar (Test 2: Drag and Drop).	25
4.5. Conjunto de 28 características globales propuestas en este TFM para la tarea de arrastra y soltar (Test 2: Drag and Drop). LDP es un punto del trazo que está más alejado de la línea recta trazada desde los puntos de contacto inicial y final del trazo 2.2.	26
4.6. Valores capturados durante el desarrollo de la tarea de ampliar/reducir (Test 3 y 4: Zoom-in y Zoom-out).	27
4.7. Conjunto de 20 características globales propuestas en este TFM para la tarea de ampliar/reducir (Test 3 y 4: Zoom-in y Zoom-out). <i>FC</i> (<i>First Curve</i>) se refiere a la curva generada por el primer dedo y <i>SC</i> (<i>Second Curve</i>) se refiere a la curva generada por el segundo dedo, ambas producidas al realizar el gesto de pinza. . .	27
4.8. Valores capturados durante el desarrollo de la tarea de recorrer la espiral (Test 5: Spiral Test).	27
4.9. Valores capturados durante el desarrollo de la tarea de colorear el árbol (Test 6: Drawing Test).	28

4.10. Conjunto de 24 características globales propuestas en este TFM para la tarea de recorrer una espiral (Test 5: Spiral Test). R_n vector con los radios de las coordenadas polares, θ_n vector con los ángulos de las coordenadas polares y t_n vector con los tiempos en segundos entre cada muestra.	29
4.11. Conjunto de 34 características globales propuestas en este TFM para la tarea de colorear un árbol (Test 6: Drawing Test). N representa el número y T el tiempo.	29
4.12. Tabla con el conjunto de 114 características adicionales utilizadas en este TFM.	30
5.1. Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “Tap and Reaction Time” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.	37
5.2. Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “Drag and Drop” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.	37
5.3. Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “Zoom-in” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.	39
5.4. Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “Zoom-out” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.	39
5.5. Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “Spiral Test” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.	41
5.6. Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “Drawing Test” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.	41
5.7. Resultados en términos de Acc. de las 15 posibles combinaciones sin repetición, en grupos de 2 ($C_{6,2}$), de los diferentes tests de ChildCI. Destacamos en verde el mejor resultado obtenido.	45
5.8. Resultados en términos de Acc. de las 20 posibles combinaciones sin repetición, en grupos de 3 ($C_{6,3}$), de los diferentes tests de ChildCI. Destacamos en verde el mejor resultado obtenido.	45
5.9. Resultados en términos de Acc. de las 15 posibles combinaciones sin repetición, en grupos de 4 ($C_{6,4}$), de los diferentes tests de ChildCI. Destacamos en verde el mejor resultado obtenido.	46
5.10. Resultados en términos de Acc. de las 6 posibles combinaciones sin repetición, en grupos de 5 ($C_{6,5}$), de los diferentes tests de ChildCI. Destacamos en verde el mejor resultado obtenido.	46
5.11. Resultados en términos de Acc. de las posibles combinaciones sin repetición, en grupos de 6 ($C_{6,6}$), de los diferentes tests de ChildCI.	46

1

Introducción

1.1. Motivación

Los niños se están convirtiendo en uno de los últimos (y más jóvenes) usuarios de la tecnología basada en la interacción táctil. Esto se traduce en un incremento en el uso de dispositivos móviles por su parte, desde smartphones y tablets a los más recientes smartwatches [1]. Podemos corroborar lo anterior basándonos en estudios recientes en la literatura [2], que muestran que más del 75,6% de los niños están expuestos a dispositivos móviles entre la edad de 1 y 60 meses. Este aspecto se ha visto agravado por el brote de la COVID-19 en 2020. Con un gran porcentaje de las instituciones académicas de todo el mundo cerradas, la educación virtual ha sustituido temporalmente a la educación tradicional en gran medida mediante aplicaciones móviles específicas de *e-Learning* en las que los niños interactúan para mejorar sus conocimientos y habilidades [3], [4].

Sin embargo, y a pesar de la importancia del tema, el campo de la Interacción Niño-Ordenador o *Child-Computer Interaction (CCI)* está todavía en sus inicios. Esto provoca que un aspecto muy importante dentro de este ámbito como es el análisis de la evolución cognitiva y motora del niño/a durante su proceso de crecimiento se siga realizando a día de hoy de forma manual, por medio de métodos tradicionales restrictivos y poco fiables [5], [6].

En este Trabajo Final de Máster (TFM) se pretende realizar un primer estudio y mejora en este campo de aplicación, analizando la forma en la que los niños interactúan con los dispositivos móviles a lo largo de su proceso de desarrollo (desde los 18 meses hasta los 8 años) mediante el uso de nuestro proyecto llamado *Child-Computer Interaction (ChildCI)*.

Los resultados obtenidos en este TFM han permitido generar un artículo de investigación, el cual ha sido enviado a la revista *IEEE Transactions on Emerging Topics in Computing*, encontrándose actualmente en proceso de revisión. Dicho artículo se encuentra disponible en el servidor público ArXiv [7].

1.2. Objetivos

Los niños experimentan muchos cambios fisiológicos y cognitivos a medida que crecen. Dichos cambios se reflejan en la forma de interactuar y entender el entorno que les rodea. Uno de los

principales objetivos del proyecto ChildCI es generar una mejor comprensión y conocimiento de la forma en que los niños interactúan con los dispositivos móviles durante el desarrollo de sus capacidades cognitivas y motoras. Con el fin de avanzar en esta dirección, en este TFM se han llevado a cabo los siguientes pasos:

- **Estudio del estado del arte.** Lo primero que se debe hacer a la hora de llevar a cabo cualquier proyecto es ponerse en el contexto adecuado. Para ello se ha realizado un estudio exhaustivo del estado del arte en la temática de interacción de los niños con los dispositivos móviles. Además de ello, se han estudiado, seleccionado y adaptado aquellos conjuntos de características más robustos y utilizados en el estado del arte para la interacción Persona-Ordenador o *Human-Computer Interaction (HCI)*.
- **Desarrollo y mejora software de la aplicación de adquisición.** Para el proceso de adquisición de la base de datos se ha utilizado una aplicación Android previamente creada y diseñada en el laboratorio de *Biometrics and Data Pattern Analytics (BiDA-Lab)* de la Universidad Autónoma de Madrid (UAM). En este TFM dicha aplicación ha sido mejorada para la correcta adquisición de la segunda fase de captura de la base de datos (ChildCIdb_v2).
- **Protocolo de captura, pre-procesado y publicación de la base de datos.** Las bases de datos disponibles en este campo de aplicación son escasas, privadas y poco adaptadas a los escenarios de la vida real. Este estudio trata de cubrir esa escasez en forma de una nueva base de datos más completa y pública llamada *ChildCIdb*¹.
- **Propuesta de nuevos conjuntos de características.** A la hora de realizar la captura de la base de datos existen diferentes tests que cada uno de los niños debe completar. En este TFM se ha analizado la validez de los diferentes tests desarrollados en ChildCI con el objetivo de poder distinguir entre los diferentes grupos de edad de los niños. De esta manera se puede probar que: *i)* los tests desarrollados en ChildCI son discriminativos para llevar a cabo esta distinción y *ii)* existen características relacionadas con aspectos motores y cognitivos que permiten medir la evolución de los niños a medida que crecen.
- **Estudio y desarrollo software de algoritmos de selección de características.** Cuando contamos con un conjunto de características amplio es necesario utilizar métodos de selección de características con el fin de seleccionar aquellas más importantes y/o relevantes del conjunto de datos. Debido a esto se ha desarrollado desde cero un Algoritmo Genético para utilizarlo como selector de características.
- **Investigación y detección de grupos de edad en niños.** Con el objetivo de poder distinguir entre los diferentes grupos de edad de los niños, en este TFM ha sido necesario: *i)* propuesta de nuevos conjuntos de características para cada test de ChildCI, *ii)* selección de aquellas características más robustas y discriminativas para la tarea de detección del grupo de edad y *iii)* desarrollo y evaluación de experimentos mediante técnicas de aprendizaje automático.
- **Desarrollo y evaluación de experimentos.** Posteriormente, se han realizado experimentos mediante el uso de diferentes técnicas y siguiendo un protocolo experimental bien definido con el objetivo de distinguir entre los diferentes grupos de edad de los niños en función de cómo estos interactúan con los dispositivos móviles. Además se han evaluado los resultados obtenidos con el fin de analizar la robustez y relevancia de los nuevos conjuntos de características propuestos en este estudio, todo ello en términos de *Accuracy (Acc.)*.

¹https://github.com/BiDALab/ChildCIdb_v1

- **Captura de una base de datos longitudinal en el tiempo.** ChildCI es un proyecto ambicioso y longitudinal en el tiempo con el cual se pretende alcanzar una comprensión de las evoluciones motoras y cognitivas de los niños durante su desarrollo. Por ello, con la colaboración de un neurólogo del Hospital Infanta Leonor y profesores del colegio GSD Las Suertes de Madrid, en este TFM se ha capturado una segunda base de datos con más de 350 niños de todas las edades.
- **Escritura de artículos de investigación.** Por último, una vez llevados a cabo los diferentes experimentos, analizando los resultados obtenidos y extrayendo conclusiones sobre el gran potencial de este proyecto, ha sido desarrollado un artículo de investigación y enviado a la revista *IEEE Transactions on Emerging Topics in Computing*, encontrándose actualmente en proceso de revisión. Dicho artículo se encuentra disponible en el servidor público ArXiv [7].

1.3. Metodología y Plan de Trabajo

Para poder cumplir con todos los objetivos propuestos se ha ideado un plan de trabajo desglosado en las siguientes fases:

- Estudio del estado del arte sobre interacción de niños con dispositivos móviles.
- Descripción del diseño software y protocolo de captura utilizado para la adquisición de la nueva base de datos ChildCIdb.
- Comprensión y análisis de la información contenida en la base de datos actual.
- Planificación y desarrollo del software necesario para el correcto desarrollo de la presente y futuras investigaciones.
- Automatización de la tarea de limpieza y preprocesamiento de la base de datos ChildCIdb.
- Incorporación manual a la base de datos de información extra de los niños proporcionada por el centro escolar y padres (lateralidad, semana de gestación, experiencia previa con dispositivos móviles, etc.).
- Definición y propuesta de nuevos métodos de aprendizaje automático para la detección de grupos de edad en niños.
- Definición de un nuevo conjunto de características robusto y específico para cada prueba/test.
- Análisis y selección de los subconjuntos de características más discriminativos.
- Estudio exhaustivo mediante la utilización de diferentes técnicas tradicionales de aprendizaje automático para clasificación con el fin de predecir el grupo de edad asociada a un niño.
- Creación de material multimedia y gráficos concluyentes a la vez que representativos sobre los resultados obtenidos durante el estudio.
- Análisis, escritura y publicación de los resultados conseguidos en el presente TFM y en una revista científica.
- Redacción de este documento y preparación de la defensa.

1.4. Estructura de la Memoria

El presente Trabajo Fin de Máster está formado por seis capítulos:

- **Capítulo 1. Introducción**
- **Capítulo 2. Estado del Arte**
- **Capítulo 3. ChildCI**
- **Capítulo 4. Detección de Grupos de Edad: Método Propuesto**
- **Capítulo 5. Experimentos y Resultados**
- **Capítulo 6. Conclusiones y Trabajo Futuro**

2

Estado del Arte

En este capítulo se describe el estado del arte en el ámbito de la interacción de los niños con los dispositivos móviles. En primer lugar, se estudian las etapas de desarrollo que sufren los niños durante su proceso de crecimiento dentro de la sección 2.1. Seguidamente, la sección 2.2 resume los estudios previos realizados sobre interacciones táctiles (*Finger/Touch*) y con el lápiz óptico (*Stylus*) realizadas por niños en dispositivos móviles dependiendo de la etapa de desarrollo en la que se encuentren. Por último, dentro de la sección 2.3 se estudian las características más robustas y utilizadas en la interacción Persona-Ordenador en el estado del arte.

2.1. Teoría de Piaget

Durante su crecimiento los niños experimentan diferentes cambios fisiológicos y cognitivos, lo que se refleja en su forma de entender e interactuar con el entorno que les rodea. Según la teoría del psicólogo suizo Jean Piaget [8], los niños construyen su propio modelo mental del mundo durante el desarrollo de cuatro etapas evolutivas diferentes:

1. **Sensoriomotor** (desde el nacimiento hasta los 2 años), centrado principalmente en la evolución del control motor, como los dedos y los gestos, y la adquisición de conocimientos a través de las experiencias sensoriales y la manipulación de objetos.
2. **Preoperacional** (2-7 años), los niños van mejorando el lenguaje y el pensamiento, mejorando también sus habilidades motoras. Además, con esta edad los niños tienen un pensamiento egocéntrico, siendo aún difícil para ellos empatizar con los sentimientos de otras personas.
3. **Operativo concreto** (7-11 años), su pensamiento se vuelve más lógico y organizado, pero sigue siendo muy concreto. En esta etapa los niños empiezan a ser capaces de ponerse en el lugar de otras personas, mejorando notablemente sus capacidades empáticas y por lo tanto, disminuyendo su pensamiento egocéntrico.
4. **Operativo formal** (adolescencia a edad adulta), empiezan a pensar más en cuestiones morales, filosóficas, éticas, sociales y políticas que requieren un razonamiento teórico y abstracto.

Cabe destacar que Piaget nunca consideró que el desarrollo cognitivo de los niños fuera un proceso cuantitativo. Es decir, él sugirió que los niños no solo mejoran los conocimientos que poseen a medida que maduran, sino que por el contrario, además existe un cambio cualitativo en su forma de pensar a medida que avanzan por cada una de las etapas descritas anteriormente.

Según Piaget las personas entienden las acciones que están involucradas en el conocimiento y la comprensión mediante esquemas mentales. Esto en los niños, al igual que en los adultos, define la forma en la que comprenden los conceptos aprendidos durante experiencias pasadas. Durante su proceso de desarrollo y al producirse nuevas experiencias, se produce la adquisición de nuevo conocimiento, lo que se traduce en una constante modificación de sus esquemas anteriores.




Figura 2.1: Esquema de asimilación-acomodación según Piaget.

Cuando los niños reciben nueva información se genera un desequilibrio en el esquema mental previo que tuvieran sobre un concepto anterior. Para volver a equilibrar el esquema, según Piaget, se produce el ciclo asimilación-acomodación, definido en la Fig. 2.1, que consta de tres fases importantes:

- **Acomodación.** Implica la modificación del esquema o idea actual como resultado de la generación de un desequilibrio esquemático debido a la adquisición de nueva información.
- **Asimilación.** Es el proceso mediante el cual se incorpora nueva información a los esquemas ya existentes. Este proceso es algo subjetivo debido principalmente a que la nueva información se modifica de forma que encaje con nuestras creencias preexistentes.
- **Equilibrio.** Es importante mantener un equilibrio entre la aplicación de conocimientos previos (asimilación) y la adopción de nuevos conocimientos (acomodación) a medida que los niños progresan en su desarrollo cognitivo y motor. Este concepto ayuda a explicar cómo los niños pasan de una etapa del pensamiento a la siguiente.

Actualmente, la mayoría de los estudios que permite estudiar la interacción de los niños con dispositivos móviles se centran en las etapas preoperacional y operativa concreta (2-11 años), señalando que los patrones de interacción táctil de los niños son diferentes en comparación con los adultos [9, 10, 11, 12]. Por ello, se deben tener en cuenta diferentes pautas para el correcto diseño y desarrollo de aplicaciones móviles para niños, valorando sus incipientes capacidades fisiológicas y cognitivas [13, 14, 15, 16].

2.2. Instrumento de Captura: Stylus vs Finger

En esta sección se han resumido los estudios anteriores realizados en el ámbito de las interacciones táctiles y con el lápiz óptico llevadas a cabo por niños. Esto nos otorga una visión general de los trabajos más recientes en este área, remarcando los conjuntos de datos disponibles públicamente para la investigación en este ámbito. En la tabla 2.1 se muestra una comparación de los estudios más relevantes de la literatura ordenados por la edad de los sujetos, incluyendo información como el número de niños considerados en el estudio, el tipo de herramienta de adquisición, etc.

Tabla 2.1: Comparación de diferentes estudios centrados en la interacción de los niños con los dispositivos móviles.

Estudio	Edad de los Participantes	# Participantes	Herramienta de Adquisición	Público
Crescenzi and Grané (2019) [16]	14-33 Meses	21	Finger	No
Nacher <i>et al.</i> (2015) [17]	2-3 Años	32	Finger	No
Hiniker <i>et al.</i> (2015) [18]	2-5 Años	34	Finger	No
Abdul-Aziz (2013) [19]	2-12 Años	33	Finger	No
Vatavu <i>et al.</i> (2015) [15]	3-6 Años	89	Finger	Sí
Vera-Rodriguez <i>et al.</i> (2020) [11]	3-6 Años	89	Finger	[15]
Acien <i>et al.</i> (2019) [12]	3-6 Años	89	Finger	[9]
Remi <i>et al.</i> (2015) [20]	3-6 Años	60	Stylus	No
Behnamnia <i>et al.</i> (2020) [21]	3-6 Años	7	Finger	No
Hussain <i>et al.</i> (2016) [22]	4-6 Años	10	Finger	No
Huber <i>et al.</i> (2016) [23]	4-6 Años	50	Finger	No
Chen <i>et al.</i> (2020) [24]	4-7 Años	28	Finger	No
Woodward <i>et al.</i> (2016) [25]	5-10 Años	30	Finger	No
Shaw and Anthony <i>et al.</i> (2016) [26]	5-10 Años	24	Finger	No
Nacher <i>et al.</i> (2018) [27]	5-10 Años	55	Finger	No
Tabatabaey-Mashadi <i>et al.</i> (2015) [28]	6-7 Años	178	Stylus	No
Anthony <i>et al.</i> (2014) [14]	6-17 Años	44	Finger	No
McKnight and Cassidy (2010) [13]	7-10 Años	80	Finger/Stylus	No
Arif and Sylla (2013) [29]	8-11 Años	12	Finger/Stylus	No
Laniel <i>et al.</i> (2020) [30]	8-11 Años	25	Stylus	No
Anthony <i>et al.</i> (2016) [10]	<12 Años	24	Finger	No
ChildCIdb [7]	18 Meses - 8 Años	438	Finger/Stylus	Sí

Una de las cosas a destacar en este campo es la falta de conjuntos de datos disponibles públicamente. Debido a esto, en este TFM se presenta una primera versión de nuestro novedoso conjunto de datos llamado *ChildCIdb*¹, el cual junto con el conjunto de datos presentado en [15] es el único disponible hasta la fecha. Actualmente se trata del mayor conjunto de datos disponible públicamente para la investigación en este ámbito, con 438 niños de edades comprendidas entre los 18 meses y los 8 años. Además, en la adquisición del conjunto de datos se tienen en cuenta los siguientes aspectos:

1. La interacción con las pantallas utilizando tanto el dedo como el lápiz óptico.
2. El estado emocional de los niños durante el proceso de adquisición.
3. La información relativa a la experiencia previa de los niños con los dispositivos móviles.
4. Las calificaciones obtenidas por los niños en el colegio.

¹https://github.com/BiDALab/ChildCIdb_v1

5. La información relativa al trastorno por déficit de atención/hiperactividad (TDAH).

Analizando los estudios centrados en la primera etapa de la teoría de Piaget (Sensoriomotor, 0-2 años), hasta donde sabemos el trabajo presentado por Crescenzi y Grané en [16] es el único disponible. Esto se produce principalmente debido a las dificultades a la hora de capturar datos de los niños en ese rango de edad (por ejemplo, a veces no quieren jugar con los dispositivos móviles). El objetivo de su estudio era analizar cómo los niños menores de 3 años interactúan con los dispositivos móviles, utilizando aplicaciones comerciales relacionadas con tareas de dibujo y coloreado. Concluyeron que los niños menores de 3 años adaptan sus gestos al contenido de las *apps* y sugirieron que el uso de las herramientas de las mismas (por ejemplo, la paleta de colores) puede comenzar a partir de los 2 años.

Muchos estudios se han centrado en la segunda etapa de la teoría de Piaget (Preoperacional, 2-7 años), prestando especial atención a la capacidad de realizar gestos en superficies multitáctiles. En [17], los autores propusieron un conjunto de 8 tareas diferentes para medir la capacidad de los niños para realizar gestos. Concluyeron que los niños de entre 2 y 3 años son capaces de realizar gestos sencillos como tocar, arrastrar y soltar, pero también otros complejos como girar con uno y dos dedos, ampliar y reducir (pinza), etc. Una línea de investigación similar se estudió en [18], revisando 100 *apps* táctiles para preescolares. Además, los autores comprobaron que los niños mayores de 3 años son capaces de seguir las instrucciones de audio de las *apps* y las demostraciones en pantalla.

Un artículo interesante en esta línea es el trabajo presentado por Vataavu *et al.* en [15]. En ese trabajo los autores capturaron y pusieron a disposición de la comunidad investigadora un conjunto de datos compuesto por 89 niños (3-6 años) y 30 adultos jóvenes. Analizaron la forma en que los niños interactúan con los dispositivos móviles, mostrando mejoras significativas en el desempeño táctil de los niños a medida que crecen de 3 a 6 años. Además, los autores propusieron diferentes pautas para el diseño de aplicaciones infantiles. Se han obtenido conclusiones similares en otros estudios de la literatura [19, 22].

Los dispositivos móviles también se han estudiado como una forma de enseñar a los niños, en particular a través de Aplicaciones de Aprendizaje Basado en Juegos Digitales o *Digital Game-Based Learning (DGBL)*. En [21], los autores investigaron si los DGBL pueden mejorar las habilidades de creatividad en los niños de preescolar (3-6 años). En el estudio se consideraron nueve juegos diferentes, concluyendo que los DGBL pueden afectar potencialmente a la capacidad de los niños para desarrollar habilidades creativas y el pensamiento crítico, la transferencia de conocimientos, la adquisición de habilidades en la experiencia digital, y una actitud positiva hacia el aprendizaje. Se extrajeron conclusiones similares en [23] al pedir a los niños que resolvieran juegos de rompecabezas.

Teniendo en cuenta que los niños y los adultos suelen utilizar diferentes patrones de interacción en los dispositivos móviles, algunos estudios han propuesto el desarrollo de sistemas automáticos para detectar grupos de edad. Esta línea de investigación tiene muchas aplicaciones potenciales diferentes, por ejemplo, restringir el acceso a contenidos o servicios para adultos, como las compras en línea. En [11], los autores presentaron un sistema automático capaz de diferenciar niños de adultos con tasas de clasificación superiores al 96 %. Este sistema de detección se centra en la combinación de características basadas en las habilidades neuromotoras, el tiempo de la tarea y la precisión. En el marco experimental se consideró el conjunto de datos publicado en [15]. En un trabajo relacionado, Acien *et al.* propuso un sistema de detección mejorado que incluye características globales de la interacción táctil [12].

No sólo se ha estudiado la interacción con la pantalla utilizando el dedo como forma de interactuar con los dispositivos móviles. Diferentes estudios han considerado el lápiz óptico como herramienta de adquisición. En [20], Remi *et al.* estudiaron las actividades de garabateo ejecutadas por niños de 3 a 6 años. Consideraron el modelo de generación de escritura Sigma-Lognormal

[11, 31] para analizar las habilidades motoras, concluyendo que existen diferencias significativas en los parámetros del modelo entre las edades. También se ha tenido en cuenta el Stylus en [28] para analizar la correlación entre el rendimiento del dibujo de formas poligonales y los niveles de rendimiento de la escritura. El estudio reveló que hay detalles en la estrategia de dibujo de los niños altamente relacionados con el rendimiento de la escritura. Recientemente, Laniel *et al.* propusieron en [30] una nueva medida de las habilidades motoras finas, el *Pen Stroke Test (PST)*, con el fin de discriminar entre los niños con y sin déficit de atención/hiperactividad (TDAH). Esta prueba también se basa en los parámetros del modelo Sigma-Lognormal, proporcionando evidencias preliminares de que el PST puede ser muy útil para detectar el TDAH.

2.3. Características Automáticas Útiles en el Análisis de la Interacción de los Niños con los Dispositivos Móviles

Para alcanzar grandes resultados en la tarea de detectar el grupo de edad asociado a los niños es importante el uso de características robustas y discriminativas que estén directamente relacionadas con aspectos motores y cognitivos de la interacción de los niños con dispositivos móviles. El problema es que a día de hoy para la generación de este tipo de características se siguen utilizando en multitud de ocasiones métodos cualitativos y bastante rudimentarios, lo que provoca que los resultados obtenidos sean menos objetivos, pudiendo variar en función del nivel de habilidad del experto encargado de generarlos.

Durante el proceso de adquisición de la base de datos de ChildCI, los niños deberán completar cada uno de los tests que se les presentan. Este tipo de tests se podrían agrupar en 2 bloques dependiendo de la herramienta de captura que se utilice en cada caso: *i)* utilizando el dedo o *ii)* utilizando el lápiz óptico o *stylus*. Por tanto, una de las partes más importantes en este TFM y siempre con el objetivo de conseguir discriminar correctamente entre los grupos de edad de los niños dependiendo de su interacción con dispositivos móviles, es el diseño de nuevas características generadas de forma automática dependiendo del tipo de herramienta utilizada. Además, combinar esto junto con el uso y adaptación de características previamente utilizadas con éxito en estudios anteriores dentro del estado del arte, supondría un enfoque más moderno y cuantitativo en el proceso de generación de características robustas y discriminativas.

Si nos centramos en aquellos tests en los que se utiliza un lápiz óptico, es un hecho decir que la firmeza y destreza de los trazos que realizan los niños en tareas manuscritas mediante el uso de esta herramienta, tales como escribir o dibujar, es debido principalmente a la madurez que experimenta su anatomía y su sistema neuromotor durante el proceso de desarrollo [8, 31], lo que es una característica diferencial a la hora de analizar la evolución motora de los niños. Por ello, si nos fijamos en la literatura y la práctica clínica, la espiral de Arquímedes es la prueba de referencia para el diagnóstico clínico de enfermedades como el temblor esencial o el Parkinson, en la que precisamente se miden características como la firmeza, la destreza y el temblor de los trazos a la hora de recorrer una espiral [32].

En [33], Ishii *et al.* desarrollaron un método cuantitativo sencillo para diagnosticar el temblor mediante espirales dibujadas a mano y el uso de Inteligencia Artificial o *Artificial Intelligence (IA)*. En el estudio los pacientes, mediante el uso de un lápiz óptico, trazaron una espiral sobre otra espiral de referencia impresa. Mediante la comparación de la longitud de la espiral de referencia y la trazada se calculó el área de desviación total entre ambas, dando lugar a resultados con tasas de hasta el 79% de acierto en la detección de personas con temblor esencial. En un trabajo relacionado, Solé *et al.* proponen un nuevo conjunto de características utilizando exclusivamente los puntos de coordenadas x e y de los trazos realizados por los pacientes a la hora de recorrer la espiral de Arquímedes utilizando un *stylus* en una tableta gráfica [34]. Por otro lado, en [35], los autores propusieron desarrollar un sistema de evaluación del temblor con paradigmas




Figura 2.2: LDP: es el punto más alejado de la línea recta entre el punto de inicio y el punto de parada de la curva de deslizamiento.

de prueba en una tableta gráfica utilizando parámetros adecuados para cuantificar automáticamente las características y la gravedad del temblor en tiempo real mediante la extracción de tres parámetros: *i)* la media de la diferencia radial por radián, *ii)* la media de la diferencia radial por segundo, y *iii)* el área bajo la curva del espectro de frecuencia de la velocidad.

Por otro lado, si nos centramos en aquellas pruebas en las que la herramienta utilizada durante la interacción con dispositivos móviles es el dedo, podemos ver que también existen multitud de estudios sobre esto [36, 37, 38]. Por ejemplo, en [39] se presenta un novedoso conjunto de características basado en la teoría Sigma-Lognormal con el objetivo de clasificar usuarios por rango de edad (niños o adultos) según su interacción con dispositivos de pantalla táctil como smartphones y tablets mediante la realización de tareas arrastrar y soltar o *Drag-and-Drop*. La teoría de Sigma-Lognormal permite representar movimientos complejos mediante un modelo analítico, el cual describe algunas características físicas y cognitivas del ser humano [40, 41]. Existen estudios como [42] que demuestran que el modelo Sigma-Lognormal puede utilizarse para caracterizar la escritura de los niños. Además, como las habilidades neuromórficas son las mismas, los principios aplicados a los modelos de escritura a mano también pueden utilizarse para modelar los patrones en una pantalla táctil.

Siguiendo en esta línea, el modelo Sigma-Lognormal establece que el perfil de velocidad de los movimientos de la mano humana puede descomponerse en pequeños trazos[15, 41, 42, 43]. Utilizando este principio, en [40], los autores presentan un sistema de verificación de firma digital en el cual para describir cada trazo se proponen 18 características que capturan los rasgos psicomotores cognitivos del firmante mediante una tableta gráfica, ofreciendo resultados muy prometedores para esta tarea.

Dentro de la interacción con dispositivos móviles utilizando el dedo como herramienta existen varios tipos de gestos que es posible realizar, tales como: *i)* deslizamiento, *ii)* pulsación de teclas, *iii)* escritura a mano, *iv)* arrastrar y soltar o *iv)* pinza/zoom, entre otros. En [44] podemos ver un estudio muy interesante en el que se usa toda esta amplia variedad de gestos con el objetivo de mejorar la seguridad y privacidad de los usuarios basándose en las operaciones táctiles que estos realizan en las pantallas de sus *smartphones*. Mediante todas estas operaciones táctiles proponen un total de 132 características, las cuales identifican la forma de interactuar que tiene cada uno

de los usuarios con su dispositivo móvil, y que aplicadas junto a técnicas de ML consiguen alcanzar una tasa de error de menos del 10 % para todas los tipos de operaciones y del 1 % para la operación de deslizamiento donde se considera el Punto de Mayor Desviación o *Largest Deviation Point (LDP)*. La Fig 2.2 muestra un ejemplo gráfico de que es el LDP de una curva de deslizamiento.

Otro rango de estudios dentro del estado del arte en la interacción táctil se centra en la extracción de características para gestos de toque (habilidades motoras gruesas) sobre pantallas de dispositivos móviles. Un estudio interesante sobre esto fué llevado a cabo en [9], donde a través de la extracción de características utilizando las coordenadas táctiles x e y capturadas durante la interacción de los sujetos con los dispositivos móviles, se consiguió clasificar el grupo de edad de los usuarios. Los resultados obtenidos fueron muy satisfactorios, alcanzando hasta un 86.5 % de acierto mediante el uso de un conjunto de datos con 119 participantes (89 de ellos niños de entre 3 y 6 años). En [45] podemos encontrar otro estudio similar en el que mediante la interacción de los usuarios con seis micro-juegos a través de una aplicación Android se propone un novedoso enfoque para salvaguardar las amenazas online que sufre la sociedad con la ayuda de técnicas de aprendizaje automático. Un conjunto de datos de más de 9000 gestos táctiles (desplazamiento, pellizco, toque y deslizamiento) fue creado gracias a la colaboración de 147 participantes, alcanzando tasas de acierto de hasta el 88 % en la detección de impostores.

Por último, en [44] y en [45] también se propusieron operaciones táctiles de tipo pinza, normalmente utilizadas para hacer funciones de ampliación/reducción en la interacción con dispositivos móviles. Este tipo de operación permite extraer información biométrica más compleja del usuario en cuestión, ya que precisan del uso de dos dedos en vez de uno, siendo categorizadas como habilidades motoras finas. En [45] el 28 % de todas las características extraídas fueron de este tipo (48 características de 171), frente al 37 % (49 características de 132) en [44].

3

ChildCI

En este TFM se presenta nuestro proyecto denominado ChildCI, el cual se centra principalmente en la comprensión de la forma en la que los niños interactúan con los dispositivos móviles permitiendo nuevas aplicaciones en ámbitos como *e-Health* [46] y *e-Learning* [47], entre otras. En particular, se introducen todos los detalles relativos al diseño y desarrollo de una nueva aplicación móvil infantil Android, el protocolo de adquisición específico considerado y las capturas primera y segunda de la base de datos de ChildCI (ChildCIdb). En el escenario considerado los niños interactúan con un dispositivo *tablet*, utilizando tanto un lápiz óptico como el dedo, realizando diferentes tareas que requieren distintos niveles de habilidades neuromotoras y cognitivas. A diferencia de la mayoría de los estudios anteriores en la literatura, este análisis considera las tres primeras etapas de la teoría de Piaget para realizar un análisis en profundidad del proceso de desarrollo de los niños. Además, ChildCI es un proyecto en curso en el que los niños serán captados en múltiples sesiones a lo largo de su proceso de desarrollo (desde los 18 meses hasta los 8 años), siendo posible extraer conocimientos muy relevantes.

La organización de esta sección es la siguiente: En la sección 3.1 se presenta el contenido y la estructura de la base de datos captada, así como las principales contribuciones de este TFM sobre la misma. La Sección 3.2 presenta la aplicación Android utilizada durante el proceso de captación junto con las tareas que la componen y las mejoras desarrolladas sobre ella en este TFM.

3.1. Base de Datos

ChildCIdb es un novedoso conjunto de datos que permite estudiar la interacción de los niños con dispositivos móviles. Se trata de un conjunto de datos en curso recogido en colaboración con el colegio GSD Las Suertes de Madrid, España. Este TFM presenta la primera y segunda captura de datos del proyecto (ChildCIdb_v1 y ChildCIdb_v2), que comprenden dos fases de captación de 438 y 374 niños respectivamente, con edades comprendidas entre los 18 meses y los 8 años, agrupados en 8 niveles educativos diferentes según el sistema educativo español. Todos los padres dieron su consentimiento informado para la correcta participación legal de sus hijos.

Además, en la adquisición del conjunto de datos se tienen en cuenta los siguientes aspectos: *i)* la interacción con los dispositivos utilizando tanto el dedo como el lápiz óptico, *ii)* el estado

emocional de los niños durante la adquisición, *iii*) la información relativa a la experiencia previa de los niños con el uso de dispositivos móviles, *iv*) las calificaciones de los niños en el colegio, *v*) la información relativa al trastorno por déficit de atención/hiperactividad (TDAH), *vi*) el sexo, *vii*) la lateralidad, *viii*) la fecha de nacimiento, y *ix*) si es prematuro (periodo de gestación inferior a 37 semanas). Toda esta información enriquece el proyecto, siendo posible investigar en varias líneas interesantes. Por ejemplo, ¿existe alguna relación entre la forma en que los niños interactúan con los dispositivos y sus calificaciones?

3.1.1. Plan Anual de Captura

Está previsto que ChildCIdb se amplíe anualmente para permitir la realización de estudios longitudinales. Los mismos niños considerados en un fase de adquisición serán adquiridos en la siguiente a medida que crezcan y pasen a los diferentes niveles educativos (de 18 meses a 8 años). Por lo tanto, las futuras versiones de ChildCIdb se ampliarán a: *i*) nuevos niños que se inscriban en el nivel educativo 2 del colegio GSD Las Suertes de Madrid, España, y *ii*) nuevas sesiones de adquisición para los niños ya captados en versiones anteriores de ChildCIdb (hasta los 8 años).

3.1.2. Protocolo de Captura

Actualmente se han realizado dos capturas de datos (*ChildCIdb_v1* y *ChildCIdb_v2*). Para la adquisición de los datos en ambas sesiones se han aplicado los siguientes principios:

- En todo momento se utilizó el mismo dispositivo (Tablet Samsung Galaxy Tab A 10.1) durante todo el proceso de adquisición para evitar problemas entre diferentes dispositivos, por ejemplo, diferentes frecuencias de muestreo [48, 49].
- Todos los niños realizaron los tests en el mismo orden (del Test 0 al Test 6) independientemente de su nivel educativo. Esto nos permite realizar una evaluación justa de los niños dentro de un nivel educativo específico y también entre diferentes niveles.
- No se proporcionó ninguna ayuda a los niños, aparte de las instrucciones indicadas en la pantalla antes del comienzo de cada prueba. En el caso de los niños menores de 3 años, también se dieron instrucciones orales siguiendo las conclusiones extraídas en [18].
- Los niños realizaron cada prueba por sí mismos, sin ninguna otra ayuda ni interacción de un tercero con el dispositivo móvil.
- La adquisición se realizó dentro de la clase habitual del niño, de uno en uno, siempre con el niño sentado lejos de los demás niños para evitar distracciones, y con el dispositivo sobre una mesa. Se permitió a los niños mover el dispositivo libremente para que se sintieran cómodos.
- La adquisición fue controlada a distancia por un integrante del laboratorio *BiDA Lab* que en todo momento actuó como supervisor del buen desarrollo de la adquisición.

3.1.3. Fase 1 de Captura (ChildCIdb_v1)

La primera versión del conjunto de datos de ChildCI (*ChildCIdb_v1*) fue capturada durante el mes de Febrero de 2020 por miembros del laboratorio *BiDA Lab*. Comprende una sesión de captación con 438 niños en total con edades comprendidas entre los 18 meses y los 8 años, agrupados en 8 niveles educativos diferentes según el sistema educativo español.

Nivel Educativo	# Sujetos	Género		Lateralidad			
		Hombre	Mujer	Derecha	Izquierda	Ambas	Desconocido
2 (1-2 Años)	18	8	10	12	3	2	1
3 (2-3 Años)	36	14	22	30	3	3	0
4 (3-4 Años)	50	29	21	38	5	7	0
5 (4-5 Años)	66	32	34	58	6	1	1
6 (5-6 Años)	93	53	40	83	8	0	2
7 (6-7 Años)	77	35	42	69	8	0	0
8 (7-8 Años)	98	48	50	79	15	0	0
Total	438	219	219	369	48	17	4

Tabla 3.1: Estadísticas del conjunto de datos ChildCIdb_v1 sobre el número de niños asociados a cada nivel educativo y la información sobre el género y la lateralidad.

Nivel Educativo	Feliz	Normal	Triste	NS/NC
2 (1-2 Años)	3	3	1	11
3 (2-3 Años)	19	1	7	9
4 (3-4 Años)	39	0	2	9
5 (4-5 Años)	52	2	0	12
6 (5-6 Años)	83	1	1	8
7 (6-7 Años)	63	2	6	6
8 (7-8 Años)	83	4	0	11
Total	342	13	17	66

Tabla 3.2: Estadísticas del análisis del estado emocional por nivel educativo para el ChildCIdb_v1. NS/NC significa "no sabe/no contesta".

En la tabla 3.1 se presentan las estadísticas de ChildCIdb_v1 relativas al número de niños asociados a cada nivel educativo, así como la información sobre el género y la lateralidad. Como se puede observar, el número de niños captados aumenta con el nivel educativo, siendo los niveles 2 y 3 los que menos sujetos tienen. Esto se produce debido a que: *i*) se agrupan menos niños en la misma clase, y *ii*) la adquisición suele ser más difícil al ser muy pequeños. En cuanto a las estadísticas de género del ChildCIdb_v1, el 50 % de los niños eran hombres/mujeres mientras que para la lateralidad, el 84 % eran diestros, aunque este factor no está completamente definido hasta los 5 años [50].

Respecto al estado emocional de los niños antes de comenzar con la adquisición de la primera versión de ChildCIdb, en la tabla 3.2 se muestran las estadísticas del análisis del estado emocional por nivel educativo. Como se puede observar, la mayoría de los niños estaban de buen humor antes del inicio de la adquisición (78 %). También es interesante destacar el elevado número de niños de entre 1 y 3 años que no proporcionaron ninguna información sobre su estado emocional (NS/NC). Esta información también será muy interesante para el proyecto con el fin de extraer cualquier relación entre el estado anímico de los niños y la forma en que interactúan con los dispositivos.

3.1.3.1. Principales Contribuciones a ChildCIdb_v1

En este TFM se ha contribuido principalmente en la mejora de 4 aspectos de ChildCIdb_v1:

1. Pre-procesado de la base de datos.

Dentro del paquete de Python de *drawingtest* implementado en este TFM, se ha desarrollado una funcionalidad creando una clase llamada *PreprocessData*. Esta funcionalidad se encarga de cubrir y comprobar aspectos como: *i*) existencia de todos los ficheros que deben

producirse y almacenarse en la base de datos tras el proceso de captura de un niño, *ii*) comprobación de la correcta estructura y formato de los valores almacenados en cada uno de los ficheros, y *iii*) limpieza y corrección de impurezas en los datos.

2. Repositorio GitHub

ChildCIdb en su primera versión (ChildCIdb_v1) es el mayor conjunto de datos disponible hasta la fecha para la investigación de la interacción de los niños con los dispositivos móviles. En este TFM se ha colaborado en su publicación mediante el desarrollo de un repositorio en GitHub¹. En este repositorio se explica de forma explícita el contenido de la base de datos, la estructura de cada uno de los ficheros, así como el funcionamiento de cada uno de los tests que se llevan a cabo durante el proceso de adquisición. Además se ofrece la posibilidad de contactar con el laboratorio *BiDA Lab* para obtener acceso al contenido de la base de datos con fines educativos y de investigación.

3. Video de Presentación

Con el ánimo de presentar la primera versión de ChildCIdb de una forma más visual y fácil de comprender para la comunidad investigadora, en este TFM se ha desarrollado y subido un video a la plataforma YouTube², donde se detalla el contenido de la base de datos. En este video se menciona a todos los autores que han trabajado en el proyecto, el objetivo principal del mismo y una explicación visual de cada uno de los bloques que componen el proceso de captación, dando un mayor alcance y repercusión al potencial del conjunto de datos.

3.1.4. Fase 2 de Captura (ChildCIdb_v2)

La segunda versión del conjunto de datos de ChildCI (ChildCIdb_v2) inicialmente estaba prevista realizarse de nuevo en colaboración con el colegio GSD Las Suertes de Madrid durante el último trimestre escolar del año 2020, es decir, durante los meses de Abril-Junio. Desgraciadamente debido a la aparición de la COVID-19, la segunda captura tuvo que posponerse y realizarse en el presente año 2021 durante los pasados meses de Mayo y Junio. Esta segunda fase de captura en el colegio GSD Las Suertes ha sido llevada a cabo como trabajo adicional de este TFM con la colaboración de personal del laboratorio *BiDA Lab* de la UAM.

Para esta segunda adquisición, y al haber transcurrido un año académico, los niños de mayor edad (nivel 8) dejan de ser captados y nuevos niños de nivel 2 (los más pequeños) entran en el estudio realizando su captación por primera vez. Esto provoca que el número total de niños capturados para esta segunda fase sea inferior que en la primera, debido principalmente a que los 98 niños de nivel 8 que teníamos en la primera fase han dejado de ser capturados para la segunda dejando su puesto a los nuevos niños más pequeños (nivel 2). Aún así ha sido posible incrementar la cantidad de niños de nivel 2 respecto a la captura anterior, pasando de capturar solo 18 niños a 40, lo que es muy buena noticia debido a que este grupo de edad es el más difícil de adquirir por su edad y porque existen menos niños de este nivel por aula.

Si observamos la tabla 3.3 podemos observar las estadísticas de ChildCIdb_v2 relativas al número de niños por nivel educativo y la información sobre el género y la lateralidad, tal y como pudimos observar en la tabla 3.1 para la primera versión de ChildCIdb. Respecto al género, la estadística sigue estando muy balanceada, en torno al 51 % de los niños son hombres y el otro 49 % mujeres. Respecto a la lateralidad, se mantiene el 84 % de niños diestros, aunque se puede observar como los valores han variado en los niveles inferiores respecto al año anterior, lo que

¹https://github.com/BiDALab/ChildCIdb_v1

²<https://youtu.be/5vnkYEqWVEA>




Figura 3.1: Comparativa gráfica de las estadísticas obtenidas sobre el número de niños asociados a cada nivel educativo y la información sobre la cantidad de niños por nivel, el género y la lateralidad en las captaciones de las versiones primera y segunda de ChildCldb.

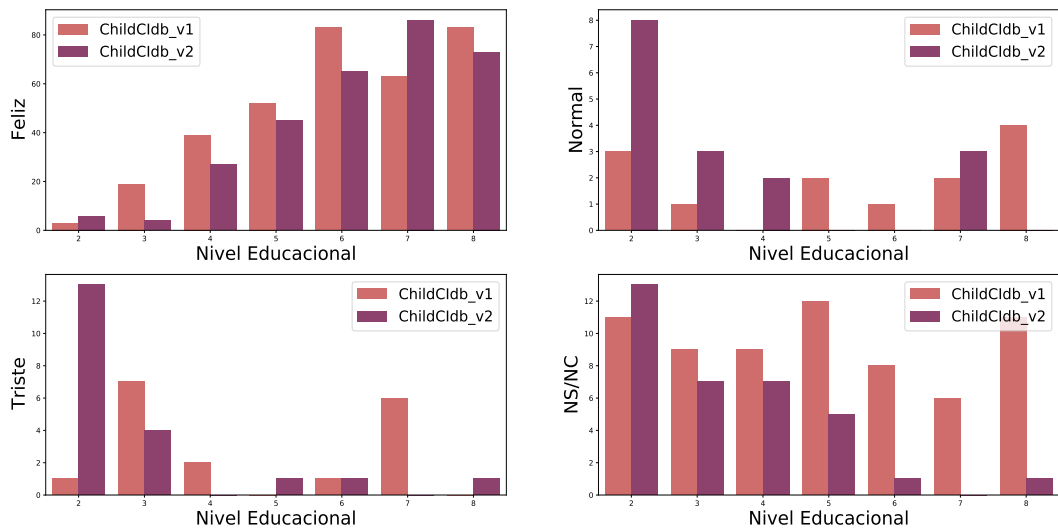


Figura 3.2: Comparativa gráfica de las estadísticas obtenidas sobre el estado anímico de los niños durante la captación de las versiones primera y segunda de ChildCldb. NS/NC significa “no sabe/no contesta”.

Nivel Educativo	# Sujetos	Género		Lateralidad			
		Hombre	Mujer	Derecha	Izquierda	Ambas	Desconocido
2 (1-2 Años)	40	25	15	28	2	10	0
3 (2-3 Años)	18	9	9	6	1	8	3
4 (3-4 Años)	36	14	22	28	4	4	0
5 (4-5 Años)	51	29	22	42	4	3	2
6 (5-6 Años)	67	33	34	62	4	0	1
7 (6-7 Años)	89	50	39	82	7	0	0
8 (7-8 Años)	75	34	41	68	7	0	0
Total	376	194	182	316	29	25	6

Tabla 3.3: Estadísticas del conjunto de datos ChildCIdb_v2 sobre el número de niños asociados a cada nivel educativo y la información sobre el género y la lateralidad.

Nivel Educativo	Feliz	Normal	Triste	NS/NC
2 (1-2 Años)	6	8	13	13
3 (2-3 Años)	4	3	4	7
4 (3-4 Años)	27	2	0	7
5 (4-5 Años)	45	0	1	5
6 (5-6 Años)	65	0	1	1
7 (6-7 Años)	86	3	0	0
8 (7-8 Años)	73	0	1	1
Total	306	16	20	34

Tabla 3.4: Estadísticas del análisis del estado emocional por nivel educativo para el ChildCIdb_v2. NS/NC significa “no sabe/no contesta”.


confirma lo estudiado en [50]. Es posible contrastar toda esta información de una forma más visual gracias a la Fig. 3.1.

Si nos fijamos ahora en las estadísticas referidas al estado emocional de los niños justo antes de comenzar con la adquisición de la segunda versión de ChildCIdb, en la tabla 3.4 podemos ver un análisis agrupado por nivel educativo. Como se puede observar la mayoría de los niños se encontraban de buen humor antes de comenzar con la adquisición, siendo el 81 % sobre el total. Por otro lado, si nos fijamos en aquellos niños de menor edad, hay un 32 % de los niños que aparentemente se encontraban tristes. Esto no es del todo cierto, debido en gran parte a que en ese punto del desarrollo la inteligencia de un niño consiste básicamente en exploraciones motoras y sensoriales básicas del mundo, y que con esas edades es cuando comienzan a relacionar nombres y palabras con sus respectivos objetos [8]. Por tanto, se puede decir que simplemente interactúan con aquello que más les llama la atención, sin necesariamente llegar a comprender el significado de su acción. Toda esta información indicada anteriormente también es posible compararla junto con la obtenida en la primera versión de ChildCIdb de una forma visual y más intuitiva gracias a la Fig. 3.2.


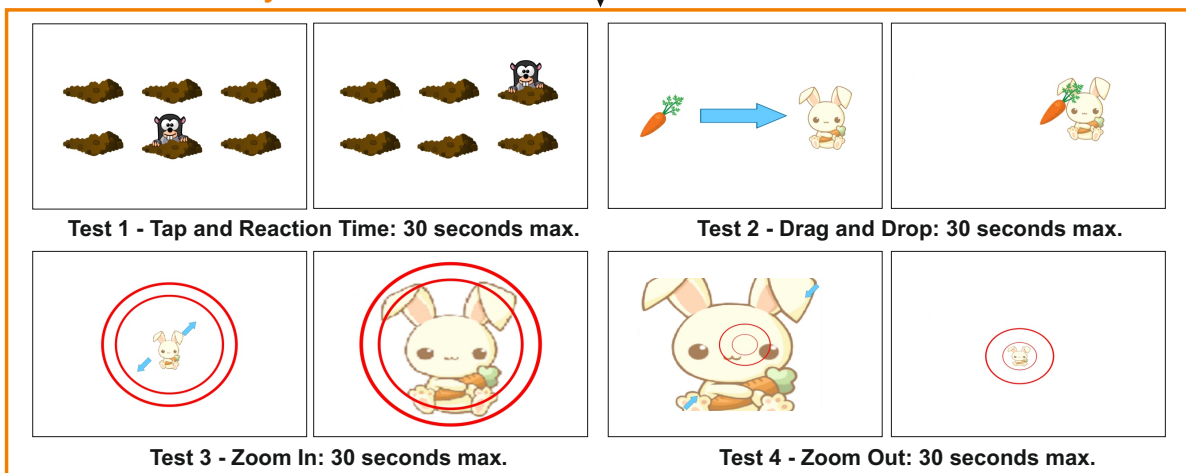
3.2. Aplicación Android

Para la adquisición de los datos, los técnicos del laboratorio *BiDA Lab* implementaron una primera versión de una aplicación móvil Android la cual comprende 7 pruebas diferentes agrupadas en 3 bloques principales: *i)* estado emocional, *ii)* táctil y *iii)* stylus. La Fig. 3.3 muestra algunos ejemplos de las diferentes interfaces diseñadas en ChildCI para cada prueba, antes y después de su ejecución. Dado que los participantes son niños, y teniendo en cuenta que no son capaces de concentrarse en la tarea durante mucho tiempo, se decidió desarrollar una aplicación de adquisición breve e interactiva para mantener su atención al máximo en un tiempo limitado.

Block 1: Emotional State Analysis



Block 2: Touch Analysis



Block 3: Stylus Analysis




Figura 3.3: Ejemplos de las diferentes interfaces diseñadas en ChildCI para cada prueba, antes y después de su ejecución, incluyendo el tiempo máximo establecido en cada una de ellas. Se consideran tres bloques principales de adquisición: *i)* emocional, *ii)* táctil y *iii)* *stylus*.

Así, se decidió establecer un tiempo máximo para cada prueba como se indica en la Fig. 3.3, siendo 5 minutos el tiempo máximo para la adquisición completa. En caso de que el niño no sea capaz de terminar cada prueba en el tiempo máximo establecido para ella, la aplicación pasa automáticamente a la siguiente prueba.

En el primer bloque, el objetivo principal es captar el estado emocional de los niños antes de comenzar la adquisición (Test 0 - Prueba de autoevaluación del estado emocional). Se representaron en la pantalla tres caras con diferentes colores y expresiones faciales, pidiendo a los niños que tocaran una de acuerdo con su estado emocional. Las tablas 3.2 y 3.4 muestran las estadísticas del análisis del estado emocional por nivel educativo para la primera y segunda versión de ChildCIdb. Como se puede observar, en ambas versiones la mayoría de los niños estaban de buen humor antes del inicio de la adquisición.

Tras la finalización del primer bloque relacionado con el análisis del estado emocional, se inicia el segundo bloque centrado en el análisis de las habilidades motoras y cognitivas de los niños utilizando su propio dedo como herramienta. Este nuevo bloque se indica a los niños a través de una imagen de ejemplo. El segundo bloque consta de 4 pruebas diferentes con distintos niveles de dificultad para ver la capacidad de los niños de realizar distintos gestos y movimientos con la mano. El tiempo máximo de cada prueba es de 30 segundos. A continuación describimos cada una de las pruebas:

- **Test 1 - Tap and Reaction Time:** en esta prueba se presenta una interfaz con un topo asomando por una de las 6 madrigueras existentes. El objetivo es que los niños toquen el topo para analizar la capacidad que tienen de realizar gestos de toque (habilidades motoras gruesas) y sus tiempos de reacción. Una vez que se toca el topo, éste desaparece de esa posición y aparece en otra posición de la pantalla. En total, hay que tocar 4 topos diferentes para finalizar la prueba. Sólo se necesita un dedo para completar la tarea.
- **Test 2 - Drag and Drop:** el objetivo es tocar la zanahoria y deslizarla hasta el conejo arrastrándola con el dedo. Esta prueba está diseñada para ver la capacidad de los niños de realizar gestos de arrastrar y soltar (motricidad fina). Para facilitar la comprensión de la prueba y motivar a los niños, se muestra una flecha azul intermitente en la pantalla hasta que los niños tocan la zanahoria. Sólo se necesita un dedo para completar la tarea.
- **Test 3 - Zoom in:** el objetivo es agrandar el conejo y ponerlo dentro de los dos círculos rojos durante un tiempo breve. Esta prueba está diseñada para:
 1. Analizar la capacidad de los niños para realizar gestos de ampliación (zoom-in).
 2. Analizar la precisión del control motor de los niños al intentar meter el conejo dentro de los dos círculos rojos (habilidades motoras finas).

Para facilitar la comprensión de la prueba, se representan dos flechas exteriores intermitentes hasta que los niños tocan la superficie cercana al conejo. El conejo sólo puede ampliarse/reducirse con dos dedos. No se permite el desplazamiento del conejo a lo largo de la pantalla para facilitar la prueba, pudiéndose sólo modificar el tamaño del conejo.

- **Test 4 - Zoom Out:** el objetivo de esta prueba es similar al test 3, pero en este caso los niños tienen que realizar gestos de reducción de escala (zoom-out). Se necesitan dos dedos para completar la prueba (habilidades motoras finas).

Una vez finalizado el segundo bloque relacionado con el análisis táctil de los niños, comienza el tercer bloque destinado a analizar la habilidad de los niños con el lápiz óptico. Esto se indica a los niños a través de un ejemplo de imagen que muestra un lápiz óptico o *stylus*. Este bloque comprende las dos pruebas siguientes:

- **Test 5 - Spiral Test:** el objetivo de esta prueba es recorrer la espiral, desde la parte interior a la exterior, intentando mantenerla siempre en la zona remarcada en color negro. Una vez que los niños terminan la prueba, deben pulsar el botón “Siguiente” para pasar a la próxima prueba. El tiempo máximo establecido para este test es de 30 segundos. Una versión similar de esta prueba se utiliza ampliamente para la detección de enfermedades como el Parkinson, el temblor esencial y otros trastornos del movimiento [33, 34, 35, 51].
- **Test 6 - Drawing Test:** el objetivo de esta prueba es colorear el árbol de la mejor manera posible. Una vez que los niños han decidido terminar la prueba, deben pulsar el botón “Siguiente”. Con esta última prueba finaliza la adquisición. El tiempo máximo establecido para este test es de 2 minutos.

Estas pruebas están diseñadas para investigar las habilidades cognitivas y neuromotoras de los niños mientras realizan acciones con sus propios dedos o utilizando el *stylus*, y también analizar su evolución con el tiempo. Los resultados de la investigación que se pueden obtener analizando ChildCI serán muy valiosos para conocer mejor las habilidades actuales de los niños en esta sociedad dominada por los dispositivos móviles.

3.2.1. Mejoras de la Aplicación Software

En este TFM se ha añadido una funcionalidad para permitir la adquisición múltiple desde diferentes entidades educativas de forma simultánea como mejora realizada sobre la aplicación Android inicial descrita en el apartado anterior. La primera versión de la aplicación se diseñó para ser funcional en la adquisición de los datos pero teniendo en cuenta que esta adquisición solo se realizaría en una única entidad educativa. Como ha sido mencionado anteriormente, ChildCI es un proyecto en curso en el que los niños serán captados en múltiples sesiones a lo largo de su proceso de desarrollo (desde los 18 meses hasta los 8 años), pero debido al potencial del proyecto se pretende, en un futuro próximo, captar más de una entidad educativa de forma simultánea, lo que sin una actualización de la aplicación sería imposible debido al diseño inicial.

Ya que los niños serán captados en múltiples sesiones (varias por año educativo) a lo largo de su proceso de desarrollo (durante varios años), en la implementación inicial se definieron dos parámetros de configuración para dictaminar a qué sesión de qué año correspondía cada adquisición:

- **“phase”:** este parámetro determina el año en el que se ha realizado la adquisición, siendo 1 el primer año de adquisición.
- **“session”:** este parámetro determina dentro de una *phase* concreta la sesión de captura que se le va a realizar a los niños, siendo 1 la primera sesión a realizar. Una misma *phase* tendrá múltiples *session*.

Una vez explicado lo anterior y con el objetivo de permitir múltiples capturas simultáneas desde distintas entidades educativas, ha sido añadido un tercer parámetro:

- **“code”:** el objetivo de este parámetro es identificar el centro educativo sobre el que se va a realizar la adquisición para una *phase* y *session* determinadas.

En la Fig. 3.4 se puede ver un esquema del nuevo flujo de información que se produce a la hora de realizar la adquisición con la nueva versión de la aplicación Android. Al iniciar la aplicación el supervisor encargado del correcto desarrollo durante la adquisición de los datos

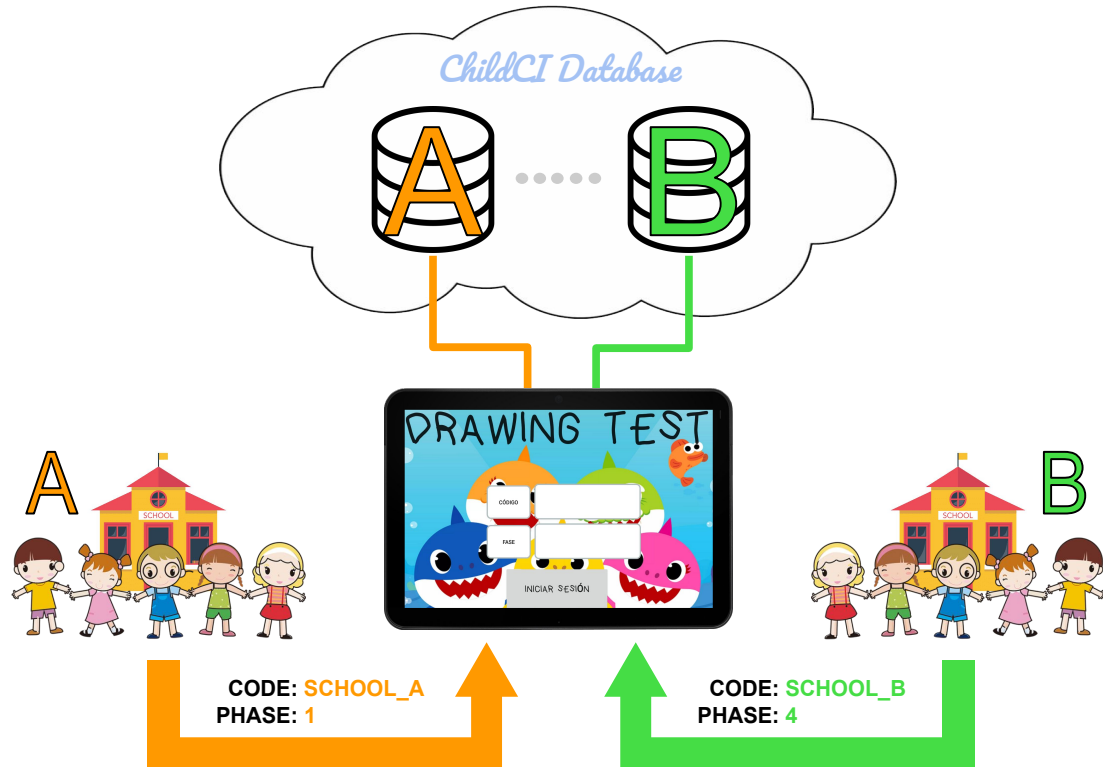


Figura 3.4: Esquema de ejemplo de una adquisición simultánea realizada sobre diferentes entidades educativas en distintas fases de captura.

deberá introducir el *code*, identificador del centro educativo, y la *phase* en la que se encuentra dicho centro. Esta modificación en un futuro permitirá no solo realizar múltiples capturas de forma simultánea en varios centros educativos, sino también en otros lugares dedicados a otro ámbito distinto al de la educación, como por ejemplo hospitales o centros de personas mayores, debido principalmente al potencial y amplio rango multidisciplinar del propio proyecto.

4

Detección de Grupos de Edad: Método Propuesto

En esta sección se analiza cuantitativamente una de las muchas y diferentes aplicaciones potenciales de ChildCIdb. El conjunto de datos utilizado ha sido la primera versión de la base de datos (ChildCIdb_v1), la cual previamente fué analizada y preprocesada. El motivo de no combinar esta información con la contenida en la segunda versión de la base de datos (ChildCIdb_v2) en el desarrollo de este estudio fué debido a que su adquisición se produjo muy recientemente, durante los pasados meses de Mayo-Junio de 2021.

En particular, este TFM se ha centrado en la popular tarea de detección del grupo de edad de los niños basada en la interacción con dispositivos móviles [9, 11, 12, 52]. Actualmente el método más popular para revelar la edad de un usuario se basa en un cuestionario en línea en el que el usuario responde directamente a preguntas sobre su edad [39]. Sin embargo, esta solución supone: *i)* honestidad en la respuesta de los usuarios, y *ii)* los usuarios saben leer. Ambas suposiciones no pueden garantizarse por muchas razones prácticas. Además de que la gente no siempre dice la verdad, hoy en día los niños empiezan a utilizar plataformas y servicios digitales antes de sin tan siquiera aprender a leer.

Con el principal objetivo de mejorar esto, en este TFM se presenta un enfoque más moderno y cuantitativo a la hora de generar de forma automática características más robustas enfocadas a esta tarea. Para ello, se han recopilado y adaptado características ampliamente utilizadas y consolidadas en el estado del arte extraídas mediante técnicas de diversos tipos y producidas para la tarea de detección del grupo de edad, entre otras. Debido al gran volumen y diversidad de información contenida en ChildCIdb_v1, ha sido posible analizar cada uno de los 7 tests que realizan los niños durante el proceso de captación, extrayendo características específicas para cada uno de ellos y aplicándolas junto a técnicas de aprendizaje automático para la tarea de detección del grupo de edad como primera etapa del proyecto y validación de los tests propuestos.

La organización de esta sección es la siguiente: La sección 4.1 describe el conjunto de características globales diseñadas en el presente TFM para cada uno de los tests incluidos en ChildCI. La sección 4.2 describe el conjunto de características adicional utilizado. Por último, en la sección 4.3 se introducen las técnicas de aprendizaje automático utilizadas en este TFM para la tarea de detección de grupo de edad.

#	Time	#	Kinematic
#	Direction	#	Pressure
#	Geometry	#	Tap
#	Drag-and-Drop	#	Zoom
#	Spiral	#	Drawing

Tabla 4.1: Tabla cuyos colores identifican el tipo de información que contiene cada una de las características de las tablas: 4.3, 4.5, 4.7, 4.10, 4.11, 4.12.

4.1. Características Globales Propuestas

La aplicación Android de ChildCI cuenta con 7 tests diferentes. Cada uno de estos tests es realizado por todos los niños del conjunto de muestra durante el proceso de captura de la base de datos. Dentro de esta sección analizaremos los conjuntos de características globales propuestos en este TFM para cada uno de estos tests con el objetivo de utilizarlos para la tarea de detección del grupo de edad asociado al niño. En total se han extraído 96 características globales en referencia a distintos tipos de habilidad: *i)* gestos de *tap*, *ii)* gestos de deslizamiento, *iii)* gestos de ampliación/reducción, *iv)* habilidades con el lápiz óptico o *stylus*. La tabla 4.1 especifica mediante colores el grupo al que pertenece cada una de las características descritas en las posteriores tablas.

Los dispositivos electrónicos utilizados durante la captación tienen un tiempo de muestreo de aproximadamente 5 milisegundos (ms) por muestra, es decir, durante la captura de datos realizada a un niño cada 5 ms se recoge una muestra de valores.

4.1.1. Test 1: Tap and Reaction Time

A la hora de realizar este test los niños se enfrentan a una pantalla en la que un topo aparece fuera de una de las seis madriguera existentes. Cada vez que el topo sea tocado con el dedo, este desaparecerá de la madriguera en la que se encuentra y aparecerá en otra diferente. El objetivo es que el niño toque el topo en cuatro ocasiones (ver figura 4.1). Los valores recogidos en esta prueba para cada una de las muestras obtenidas durante el proceso de captación pueden verse en la tabla 4.2.

Utilizando todo esto, en este TFM se presenta un conjunto de 5 características específicas (ver la tabla 4.3) para este test con el objetivo de utilizarlas junto con algoritmos de aprendizaje automático para la tarea de detección del grupo de edad de los niños. Concretamente 4 de estas características están inspiradas en el estudio realizado en [9].

4.1.2. Test 2: Drag and Drop

El objetivo de este test es que los niños realicen la tarea de arrastrar un objeto y soltarlo. Al iniciar la prueba aparecen: una zanahoria en la parte izquierda de la pantalla y un conejo en la parte derecha. El objetivo es que los niños toquen la zanahoria con un dedo y se la lleven al conejo arrastrándola por la pantalla (ver figura 4.2). Los valores recogidos durante el desarrollo de esta prueba en forma de muestras pueden verse en la tabla 4.4.

Gracias a esta información ha sido posible desarrollar un total de 28 características globales específicas para esta tarea. Este conjunto podemos verlo de forma más detallada en la información




Figura 4.1: Desarrollo del “Test 1: Tap and Reaction Time”. A la izquierda, el test al comienzo. A la derecha, el test al finalizar.

Value	Description	Value	Description
x	X-coordinate	y_min	Minimum Y-coordinate value for the mole
y	Y-coordinate	y_max	Maximum Y-coordinate value for the mole
timestamp	Time instant at which the sample was taken for that row	pressure	Pressure exerted by the child [0,1]
x_min	Minimum X-coordinate value for the mole	inTarget	Indicates whether the child is touching the mole or not
x_max	Maximum X-coordinate value for the mole	action	Indicates the type of action the child is performing (0: starts pen-down, 1: starts pen-up, 2: pen-down)

Tabla 4.2: Valores capturados durante el desarrollo de la tarea de *tap* (Test 1: Tap and Reaction Time)

#	Feature Description	#	Feature Description
1	Average distance between tap and center of mole	2	Standard Deviation distance between tap and center of mole
3	Maximum distance between tap and center of mole	4	Minimum distance between tap and center of mole
5	Number of moles touched		

Tabla 4.3: Conjunto de 5 características globales propuestas en este TFM para la tarea de tocar (Test 1: Tap and Reaction Time).



Figura 4.2: Desarrollo del “Test 2: Drag and Drop”. A la izquierda, el test al comienzo. A la derecha, el test al finalizar.

Value	Description	Value	Description
x	X-coordinate	y_min	Minimum Y-coordinate value for the rabbit
y	Y-coordinate	y_max	Maximum Y-coordinate value for the rabbit
timestamp	Time instant at which the sample was taken for that row	pressure	Pressure exerted by the child [0,1]
x_min	Minimum X-coordinate value for the rabbit	inTarget	Indicates whether the child is touching the carrot or not
x_max	Maximum X-coordinate value for the rabbit	action	Indicates the type of action the child is performing (0: starts pen-down, 1: starts pen-up, 2: pen-down)

Tabla 4.4: Valores capturados durante el desarrollo de la tarea de arrastrar soltar (Test 2: Drag and Drop).

#	Feature Description	#	Feature Description
1	Average LDP Size	2	Standard Deviation LDP Size
3	Average LDP Velocity	4	Standard Deviation LDP Velocity
5	Average Start-to-LDP Latency (ms)	6	Standard Deviation Start-to-LDP Latency (ms)
7	Average Straight Start-to-LDP Length	8	Standard Deviation Straight Start-to-LDP Length
9	Average Start-to-LDP Direction	10	Standard Deviation Start-to-Stop Direction
11	Average Start-to-Stop Latency (ms)	12	Standard Deviation Start-to-Stop Latency (ms)
13	Average Straight Start-to-Stop Length	14	Standard Deviation Straight Start-to-Stop Length
15	Average Start-to-Stop Direction	16	Standard Deviation Start-to-Stop Direction
17	Average LDP-to-Stop Latency (ms)	18	Standard Deviation LDP-to-Stop Latency (ms)
19	Average Straight LDP-to-Stop Length	20	Standard Deviation LDP-to-Stop Length
21	Average LDP-to-Stop Direction	22	Standard Deviation LDP-to-Stop Direction
23	Average Start Point Velocity	24	Standard Deviation Start Point Velocity
25	Average Stop Point Velocity	26	Standard Deviation Stop Point Velocity
27	The carrot has been touched in the first pen-down	28	Carrot ends up in the rabbit (target)

Tabla 4.5: Conjunto de 28 características globales propuestas en este TFM para la tarea de arrastra y soltar (Test 2: Drag and Drop). LDP es un punto del trazo que está más alejado de la línea recta trazada desde los puntos de contacto inicial y final del trazo 2.2.



Figura 4.3: Desarrollo del “Test 3 y 4: Zoom-in y Zoom-out”. A la izquierda, el “Test3: Zoom-in al comenzar y al terminar”. A la derecha, el “Test4: Zoom-out al comenzar y al terminar”.

contenida en la tabla 4.5. En concreto, del conjunto presentado de 28 características: 15 de ellas han sido ideadas en este TFM y 13 están basadas en el estudio [44].

4.1.3. Test 3 y 4: Zoom-in y Zoom-out

Para esta tarea los niños deben mostrar sus habilidades motoras finas realizando gestos más complejos mediante el uso de 2 dedos. En ambas pruebas en la pantalla al comenzar aparece un conejo, muy grande o muy pequeño, el cual debe ampliarse o reducirse dejándolo entre los dos círculos rojos durante unos segundos, dependiendo de la prueba (ver figura 4.3). En la tabla 4.6 es posible observar cada uno de los valores recogidos para esta prueba durante el proceso de captura.

Utilizando esta información se ha desarrollado un conjunto de 20 características específicas para la tarea de ampliar/reducir. En concreto: 8 de ellas han sido ideadas específicamente para esta prueba, 4 están basadas en el estudio realizado en [45] y las 8 restantes están inspiradas en [44]. Podemos ver este conjunto de características en la tabla 4.7.

4.1.4. Test 5: Spiral Test

Al comenzar esta tarea en la pantalla aparece la silueta de una espiral. El objetivo es que los niños recorran la espiral, utilizando el lápiz óptico, desde dentro hacia fuera intentando salirse lo mínimo posible de la zona remarcada en color negro (ver figura 4.4). Los valores registrados durante el transcurso de este test pueden verse en la tabla 4.8.

Value	Description	Value	Description
x	X-coordinate	x_max	Maximum X-coordinate value for the rabbit
y	Y-coordinate	y_min	Minimum Y-coordinate value for the rabbit
timestamp	Time instant at which the sample was taken for that row	y_max	Maximum Y-coordinate value for the rabbit
xCircle	X-coordinate of the centre of the two red circles	scale	Scaling factor for the size of the rabbit
yCircle	Y-coordinate of the centre of the two red circles	pressure	Pressure exerted by the child [0,1]
r1	Radius of the inner circle	inTarget	Indicates when the rabbit is between the two red circles
r2	Radius of the outer circle	action	Indicates the type of action the child is performing (0: starts pen-down, 1: starts pen-up, 2: pen-down first finger, 3: pen-down second finger)
x_min	Minimum X-coordinate value for the rabbit		

Tabla 4.6: Valores capturados durante el desarrollo de la tarea de ampliar/reducir (Test 3 y 4: Zoom-in y Zoom-out).

#	Feature Description	#	Feature Description
1	Total time on target (ms)	2	Reaction time until using 2 fingers (ms)
3	Maximum scale	4	Minimum scale
5	Average scale	6	Standard Deviation Scale
7	# Samples using 2 fingers	8	# Samples using 1 finger
9	Average V_x FC	10	Average V_y FC
11	Average V_x SC	12	Average V_y SC
13	FC Trajectory Length	14	SC Trajectory Length
15	FC Trajectory Velocity	16	SC Trajectory Velocity
17	Start distance between both fingers	18	Stop distance between both fingers
19	FC Straight Length	20	FC Straight Length

Tabla 4.7: Conjunto de 20 características globales propuestas en este TFM para la tarea de ampliar/reducir (Test 3 y 4: Zoom-in y Zoom-out). *FC* (*First Curve*) se refiere a la curva generada por el primer dedo y *SC* (*Second Curve*) se refiere a la curva generada por el segundo dedo, ambas producidas al realizar el gesto de pinza.

Value	Description	Value	Description
x	X-coordinate	pressure	Pressure exerted by the child [0,1]
y	X-coordinate	inTarget	Indicates whether the child draws inside the spiral (area highlighted in black) or not
timestamp	Time instant at which the sample was taken for that row	action	Indicates the type of action the child is performing (0: starts pen-down, 1: starts pen-up, 2: pen-down)

Tabla 4.8: Valores capturados durante el desarrollo de la tarea de recorrer la espiral (Test 5: Spiral Test).



Figura 4.4: Desarrollo del “Test 5: Spiral Test”. A la izquierda, el test al comienzo. A la derecha, el test al finalizar.




Figura 4.5: Desarrollo del “Test 6: Drawing Test”. A la izquierda, el test al comienzo. A la derecha, el test al finalizar.

Value	Description	Value	Description
x	X-coordinate	pressure	Pressure exerted by the child [0,1]
y	X-coordinate	inTarget	Indicates whether the child draws inside the tree or not
timestamp	Time instant at which the sample was taken for that row	action	Indicates the type of action the child is performing (0: starts pen-down, 1: starts pen-up, 2: pen-down)

Tabla 4.9: Valores capturados durante el desarrollo de la tarea de colorear el árbol (Test 6: Drawing Test).

Utilizando estos valores, 24 características han sido desarrolladas para esta prueba. En concreto: 3 de ellas están basadas en el estudio realizado en [33], 14 se basan en [34], 2 se apoyan en los resultados obtenidos por [35] y las 5 restantes han sido ideadas específicamente para esta tarea en este TFM. Podemos ver este conjunto de características en la tabla 4.10.

4.1.5. Test 6: Drawing Test

En este test aparece un árbol en la pantalla del dispositivo móvil. El objetivo es que los niños coloreen el árbol con la ayuda del lápiz óptico de la mejor forma posible (ver figura 4.5). En la tabla 4.9 pueden verse los valores recogidos para cada una de las muestras obtenidas durante el proceso de captación de esta prueba.

Utilizando todo lo anterior, en este TFM se presentan 34 características específicamente diseñadas para la prueba de colorear un árbol. La tabla 4.11 describe este novedoso conjunto de 34 características globales, que extrae información relevante como la longitud de los trazos del dibujo y el número de veces que los niños colorean fuera del margen del árbol, entre otras muchas cosas.

4.2. Características Globales Adicionales

Además de las 96 características globales propuestas en este TFM, también han sido utilizadas 114 características basadas en estudios preliminares en el campo de la Interacción Persona-Ordenador. Este conjunto de características es ampliamente utilizado en el estado del arte [53, 54, 55] y está relacionado con la información de Tiempo, Cinemática, Dirección, Geometría y Presión. Ambos conforman un conjunto final de 210 características. En la tabla 4.12 se describe este conjunto de 114 características adicionales.

#	Feature Description	#	Feature Description
1	Spiral length	2	Average(Distance between points)
3	STD(Distance between points)	4	Response time (seconds)
5	Sample Entropy (SENT) [m=3, r=0.2]	6	Mean Absolute Value (MAV) $\frac{1}{N} \sum_{i=1}^N R_i $
7	Variance (VAR) $\frac{1}{N-1} \sum_{i=1}^N R_i - \mu ^2$	8	Root Mean Square (RMS) $\sum_{i=1}^N \frac{1}{N} R_i^2$
9	Log Detector (LOG) $e^{\frac{1}{N} \sum_{i=1}^N \log(R_i)}$	10	Waveform Length (WL) $\sum_{i=1}^{N-1} R_{i+1} - R_i $
11	Standard Deviation (STD) $\sqrt{\frac{1}{N-1} \sum_{i=1}^N R_i - \mu ^2}$	12	Difference Absolute Standard Deviation (ACC) $\sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} R_{i+1} - R_i ^2}$
13	Fractal Dimension (FD) [Higuchi's Algorithm with m=5]	14	Maximum Fractal Length (MFL) $\log(\sum_{i=1}^{N-1} R_{i+1} - R_i)$
15	Integrated EMG (IEMG) $\sum_{i=1}^N R_i $	16	Simple Square EMG (SSI) $\sum_{i=1}^N R_i^2$
17	Zero Crossing (ZC) [# times the signal crosses its mean]	18	Slope Sign Change (SSC) [# times the slope of the sign changes]
19	Mean of Radial Difference Per Radian $\frac{1}{N} \sum_{i=1}^{N-1} \left \frac{R_{i+1} - R_i}{\theta_{i+1} - \theta_i} \right $	20	Mean of Radial Difference Per Second $\frac{1}{N} \sum_{i=1}^{N-1} \left \frac{R_{i+1} - R_i}{t_{i+1} - t_i} \right $
21	# Maximums in R_n	22	# Minimums in R_n
23	Global Maximum Quartile of R_n	24	Global Minimum Quartile of R_n

Tabla 4.10: Conjunto de 24 características globales propuestas en este TFM para la tarea de recorrer una espiral (Test 5: Spiral Test). R_n vector con los radios de las coordenadas polares, θ_n vector con los ángulos de las coordenadas polares y t_n vector con los tiempos en segundos entre cada muestra.

#	Feature Description	#	Feature Description
1	N (draw outside the tree margin)	2	N (pen-downs)
3	N (time samples inside the tree margin)	4	N (time samples outside the tree margin)
5	N_{max} (pen-down time samples)	6	T_{max} (pen-down)
7	N_{min} (pen-down time samples)	8	T_{min} (pen-down)
9	T_{mean} (pen-down)	10	N_{max} (pen-up time samples)
11	T_{max} (pen-up)	12	N_{min} (pen-up time samples)
13	T_{min} (pen-up)	14	T_{mean} (pen-up)
15	$Mean$ (X-coordinate spatial position)	16	$Mean$ (Y-coordinate spatial position)
17	Std (X-coordinate spatial position)	18	Std (Y-coordinate spatial position)
19	N (changes in drawing direction)	20	Max (X-coordinate spatial position)
21	Min (X-coordinate spatial position)	22	Max (Y-coordinate spatial position)
23	Min (Y-coordinate spatial position)	24	End test before time? (Yes/No)
25	T (drawing inside the tree margin)	26	T (drawing outside the tree margin)
27	T (drawing)	28	T (not drawing)
29	T (drawing inside the tree margin) / T (drawing)	30	T (drawing outside the tree margin) / T (drawing)
31	T (drawing inside the tree margin) / T (drawing outside the tree margin)	32	T (drawing) / T (Test)
33	Draw anything? (Yes/No)	34	N (time samples)

Tabla 4.11: Conjunto de 34 características globales propuestas en este TFM para la tarea de colorear un árbol (Test 6: Drawing Test). N representa el número y T el tiempo.

#	Feature Description	#	Feature Description
0	Signature total duration T_s	1	(pen-down duration T_w) / T_s
2	(1st t(v_{max})) / T_w	3	$T(v_x > 0)$ / T_w
4	$T(v_x < 0)$ / T_w	5	$T(v_y > 0)$ / T_w
6	$T(v_y < 0)$ / T_w	7	$T(1^{st} \text{ pen-up})$ / T_w
8	$T(2^{nd} \text{ pen-up})$ / T_w	9	$T(2^{nd} \text{ pen-down})$ / T_s
10	$T(3^{rd} \text{ pen-down})$ / T_s	11	(1st t($v_{y,max}$)) / T_w
12	(1st t($v_{y,min}$)) / T_w	13	(1st t($v_{x,max}$)) / T_w
14	(1st t($v_{x,min}$)) / T_w	15	$T(\text{curvature} > \text{threshold}_{curv})$ / T_w
16	(1st t(x_{max})) / T_w	17	(2nd t(x_{max})) / T_w
18	(3rd t(x_{max})) / T_w	19	(1st t(y_{max})) / T_w
20	(2nd t(y_{max})) / T_w	21	(3rd t(y_{max})) / T_w
22	(average velocity \bar{v}) / v_{max}	23	$N(v_x = 0)$
24	$N(v_y = 0)$	25	$\backslash \text{bar}\{v\}$ / $v_{x,max}$
26	$\backslash \text{bar}\{v\}$ / $v_{y,max}$	27	(velocity rms v) / v_{max}
28	(centripetal acceleration rms a_c) / a_{max}	29	(tangential acceleration rms a_t) / a_{max}
30	(acceleration rms a) / a_{max}	31	(integrated abs. Centr. Acc. a_{Ic}) / a_{max}
32	(velocity correlation $v_{x,y}$) / v_{max}^2	33	standard deviation of v_x
34	standard deviation of v_y	35	standard deviation of a_x
36	standard deviation of a_y	37	average jerk \bar{J}
38	\bar{J}_x	39	\bar{J}_y
40	j_{max}	41	$j_{x,max}$
42	$j_{y,max}$	43	j_{rms}
44	t(j_{max}) / T_w	45	t($j_{x,max}$) / T_w
46	t($j_{y,max}$) / T_w	47	$\phi(\text{initial direction})$
48	$\theta(1^{st} \text{ to } 2^{nd} \text{ pen-down})$	49	$\theta(1^{st} \text{ pen-down to } 2^{nd} \text{ pen-up})$
50	$\theta(1^{st} \text{ pen-down to } 2^{nd} \text{ pen-up})$	51	$\theta(2^{nd} \text{ pen-down to } 3^{rd} \text{ pen-up})$
52	$\theta(\text{before last pen-up})$	53	$\theta(1^{st} \text{ pen-down to last pen-up})$
54	direction histogram s_1	55	direction histogram s_2
56	direction histogram s_3	57	direction histogram s_4
58	direction histogram s_5	59	direction histogram s_6
60	direction histogram s_7	61	direction histogram s_8
62	direction change histogram c_2	63	direction change histogram c_3
64	direction change histogram c_4	65	$N(\text{pen-ups})$
66	$N(\text{sign changes of } d_x/d_t \text{ and } d_y/d_t)$	67	$\frac{T((d_x/d_t)/(d_y/d_t) > 0)}{T((d_x/d_t)/(d_y/d_t) < 0)}$
68	$\frac{T((d_y/d_t)/(d_x/d_t) > 0)}{T((d_y/d_t)/(d_x/d_t) < 0)}$	69	$\frac{A_{min} = (y_{max} - y_{min})(x_{max} - x_{min})}{(\Delta x = \sum_{i=1}^{pen-downs} (x_{max[i]} - x_{min[i])) \Delta y}$
70	(max distance between points) / A_{min}	71	$(x_{1stpen-down} - x_{max}) / \Delta x$
72	$(x_{1stpen-down} - x_{min}) / \Delta x$	73	$(x_{lastpen-up} - x_{max}) / \Delta x$
74	$(x_{lastpen-up} - x_{min}) / \Delta x$	75	$(y_{1stpen-down} - y_{max}) / \Delta y$
76	$(y_{1stpen-down} - y_{min}) / \Delta y$	77	$(y_{lastpen-up} - y_{max}) / \Delta y$
78	$(y_{lastpen-up} - y_{min}) / \Delta y$	79	$((x_{max} - x_{min}) \Delta_y) / ((y_{max} - y_{min}) \Delta_x)$
80	(standard deviation of x) / Δ_x	81	(standard deviation of y) / Δ_y
82	$(T_w \bar{v})(x_{max} - x_{min})$	83	$(T_w \bar{v})(y_{max} - y_{min})$
84	$(x_{max} - x_{min}) / x_{acquisitionrange}$	85	$(y_{max} - y_{min}) / y_{acquisitionrange}$
86	$(\bar{x} - x_{min}) / \bar{x}$	87	spatial histogram t_1
88	spatial histogram t_2	89	spatial histogram t_3
90	spatial histogram t_4	91	$N(\text{local máxima in x})$
92	$(x_{2ndlocalmax} - x_{1stpen-down}) / \Delta x$	93	$(x_{3rdlocalmax} - x_{1stpen-down}) / \Delta x$
94	$N(\text{local maxima in y})$	95	$(y_{2ndlocalmax} - y_{1stpen-down}) / \Delta y$
96	$(y_{3rdlocalmax} - y_{1stpen-down}) / \Delta y$	97	average pressure \bar{z}
98	median pressure	99	$N(\text{Pen Downs samples})$
100	$N(\text{Pen Ups samples})$	101	median $N(\text{Pen Ups samples})$ individually
102	average $N(\text{Pen Ups samples})$ individually	103	median $N(\text{Pen Downs samples})$ individually
104	average $N(\text{Pen Downs samples})$ individually	105	\bar{z} / p_{max}
106	$(\bar{z} - z_{min}) / \bar{z}$	107	median pressure last pen-down
108	average pressure last pen-down	109	median pressure first pen-down
110	average pressure first pen-down	111	$(z_{max} - z_{min}) / \bar{z}$
112	average velocity \bar{z}	113	average acceleration \bar{a}

Tabla 4.12: Tabla con el conjunto de 114 características adicionales utilizadas en este TFM.

4.3. Técnicas de Machine Learning

En este TFM se estudian diferentes enfoques de aprendizaje automático. Los sistemas de detección de grupos de edad propuestos constan de tres módulos principales: *i)* extracción de características, *ii)* selección de características y *iii)* clasificación. Los parámetros específicos de cada enfoque han sido seleccionados sobre el conjunto de datos de desarrollo.

4.3.1. Extracción de Características

Sobre cada test llevado a cabo en ChildCI durante el proceso de adquisición realizado sobre los niños se extrae de manera automática un conjunto de N características globales, donde N varía en función del test analizado:

1. **Test 1: Tap and Reaction Time.** Para este test un total de 190 características son extraídas, de las cuales: 99 corresponden a las características adicionales presentadas en la tabla 4.12 (no se generan las 15 características referidas a *pressure* debido a que en los tests en los que la herramienta de captación utilizada es el dedo la presión ejercida por el niño es siempre constante), 34 corresponden a las propuestas en la tabla 4.11, 24 a las propuestas en la tabla 4.10, 28 corresponden a las presentadas en la tabla 4.5 y por último, el conjunto de 5 características globales específicas presentado para este test en la tabla 4.3.
2. **Test 2: Drag and Drop.** Para este test son extraídas un total de 185 características, de las cuales: 99 corresponden a las características adicionales presentadas en la tabla 4.12 (tampoco se generan las 15 características referidas a *pressure*), 34 corresponden a las propuestas en la tabla 4.11, 24 a las propuestas en la tabla 4.10 y finalmente, las 28 características globales presentadas específicamente para este test en la tabla 4.5.
3. **Test 3 y 4: Zoom-in y Zoom-out.** Los valores capturados durante el proceso de captación para estos dos tests son muy diferentes respecto al resto, como podemos ver en la tabla 4.6, debido principalmente a que esta prueba requiere del uso de dos dedos. Por consiguiente, para este test son extraídas un total de 35 características globales, de las cuales: 20 han sido diseñadas específicamente para este test y presentadas en la tabla 4.7, 3 han sido reutilizadas del conjunto de características adicionales presentado en la tabla 4.12, 11 han sido reutilizadas del conjunto de 34 características propuestas en la tabla 4.11 y por último, 1 ha sido rescatada del conjunto presentado en la tabla 4.10.
4. **Test 5: Spiral Test.** Para este test un total de 172 características han sido generadas, de las cuales: 114 corresponden a las características adicionales presentadas en la tabla 4.12, 34 corresponden a las presentadas en la tabla 4.11 y 24 corresponden al conjunto diseñado específicamente para este test y presentado en la tabla 4.10.
5. **Test 6: Drawing Test.** Para este test un total de 148 características globales han sido generadas, de las cuales: 114 corresponden a las características adicionales presentadas en la tabla 4.12 y 34 han sido diseñadas específicamente para este test y presentadas en la tabla 4.11.

Para el análisis de cada test, siempre que ha sido posible, se ha reutilizado el mayor número de características previamente desarrolladas, aunque estas no estuvieran idealmente diseñadas para la tarea en cuestión. Esto se ha realizado de esta forma debido a que durante el análisis individual de cada test, técnicas automáticas de selección de características han sido utilizadas con el

objetivo de escoger aquellas características que junto con métodos de aprendizaje automático fueran las más discriminativas para la tarea de detección de los grupos de edad asociados a los niños. Dichas técnicas son presentadas en la siguiente sección.

4.3.2. Selección de Características

Diferentes técnicas de selección de características han sido utilizadas para seleccionar las características más discriminativas del total de 210 características globales extraídas originalmente:

- **Fisher Discriminant Ratio (FDR):** mide el poder discriminativo de cada característica global independiente [56]. El valor aumenta con la variabilidad interclase y disminuye con la variabilidad intraclase. En nuestros experimentos seleccionamos el subconjunto de características globales cuyos valores de FDR son superiores a 0.05.
- **Sequential Forward Floating Search (SFFS):** este algoritmo tiene como objetivo seleccionar el subconjunto de características óptimas para un criterio de optimización específico, reduciendo al mismo tiempo el número de posibles combinaciones a probar. Por lo tanto, este algoritmo ofrece una solución subóptima ya que no tiene en cuenta todas las posibles combinaciones de características, aunque sí considera las correlaciones entre las mismas, logrando resultados de alta precisión [57]. La implementación específica considerada en este estudio está disponible públicamente en MLxtend¹.
- **Algoritmo Genético (AG):** este algoritmo se inspira en la teoría de la evolución natural de Charles Darwin, basándose en operaciones de inspiración biológica como la mutación, el cruce y la selección; y encuentra una buena aplicación para la selección de características en la biometría de la escritura [58]. Se ha considerado el algoritmo genético presentado originalmente en [59]. Este algoritmo ha sido completamente programado en este TFM desde cero, incluyendo aspectos como la ejecución en paralelo para acelerar el proceso de selección de características. El código implementado en Python está disponible públicamente en GitHub². En nuestros experimentos han sido considerados los siguientes parámetros: generaciones aleatorias = 100, población = 200, tasa de cruce = 0.6, tasa de mutación = 0.05.

4.3.3. Clasificación

Dentro del marco experimental utilizado en este TFM se estudian diferentes clasificadores. Todos ellos están disponibles públicamente en Scikit-Learn³. Además, para cada clasificador, los parámetros óptimos se seleccionan después de una búsqueda en profundidad sobre el conjunto de datos de desarrollo utilizando la clase *GridSearchCV* de Scikit-Learn mediante tuneo de hiperparámetros.

- **Naive Bayes (NB):** se trata de un clasificador probabilístico simple basado en el teorema de Bayes con la suposición “ingenua” de independencia condicional entre cada par de características dado el valor de la variable de clase.
- **Logistic Regression (LR):** se trata de un clasificador estadístico que modela la probabilidad de una determinada clase utilizando funciones logísticas. En los experimentos llevados a cabo en este TFM, se ha considerado la regularización L2.

¹<http://rasbt.github.io/mlxtend/>

²<https://github.com/BiDALab/GeneticAlgorithm>

³<https://scikit-learn.org/stable/>

- **K-Nearest Neighbours (K-NN):** se trata de un método no paramétrico en el que un evento se asigna a la clase más común entre sus k vecinos más cercanos. En los experimentos llevados a cabo en este TFM, el número de vecinos ha sido de 5, y el algoritmo utilizado para calcular los vecinos más cercanos es *BallTree*, entre otros.
- **Random Forest (RF):** se trata de un método de aprendizaje de conjunto que ajusta un número de clasificadores de árboles de decisión en el momento del entrenamiento y da como resultado la clase que es la modalidad de las clases de los árboles individuales. En nuestros experimentos, el número de árboles en el bosque es de 100, la profundidad máxima del árbol es de 75, y la función para medir la calidad de la división es “gini”, entre otros.
- **AdaBoost (AB):** combina múltiples “clasificadores débiles” en un único “clasificador fuerte”. Comienza ajustando un clasificador en el conjunto de datos original y, a continuación, ajusta copias adicionales del clasificador en el mismo conjunto de datos, pero en el que los pesos de las instancias clasificadas incorrectamente se ajustan de manera que los clasificadores posteriores se centran más en los casos difíciles. Para este clasificador el enfoque AdaBoost-SAMME presentado en [60] ha sido utilizado con 50 estimadores como máximo, entre otros.
- **Support Vector Machines (SVM):** se trata de un popular algoritmo de aprendizaje que construye un hiperplano o conjunto de hiperplanos en un espacio de alta o infinita dimensión que separa mejor las clases. En este caso, la regularización ha sido seleccionada con un valor de 0.1, el kernel polinómico de grado 3 y el coeficiente escalado, entre otros.
- **Multi-Layer Perceptron (MLP):** es una clase de Red Neural Artificial o Artificial Neural Network (ANN). Consta de tres o más capas (una de entrada y otra de salida con una o más capas ocultas) de nodos de activación no lineal. Cada nodo está conectado a todos los nodos de la capa siguiente (totalmente conectado). En este TFM, se han considerado cuatro capas ocultas con 100, 200, 200 y 100 neuronas para cada capa oculta, respectivamente. Además, se considera el optimizador “Adam” con parámetros por defecto (tasa de aprendizaje de 0.001) y una función de pérdida basada en la “entropía cruzada”, entre otros.

5

Experimentos y Resultados

En este capítulo se describen y analizan los experimentos realizados en este TFM para la tarea de detección del grupo de edad de los niños en la interacción con dispositivos móviles utilizando el conjunto de datos ChildCIdb_v1. En la sección 5.1 se detalla el protocolo experimental. A su vez, se van a explicar los distintos experimentos realizados sobre cada uno de los tests de ChildCI en la sección 5.2. Finalmente, una combinación de los mejores modelos obtenidos para cada test será presentada en la sección 5.3.

5.1. Protocolo Experimental

El protocolo experimental propuesto en este TFM se ha diseñado para detectar tres grupos diferentes de niños: Grupo 1 (niños de niveles educativos 2 y 3, es decir, de 1 a 3 años), Grupo 2 (niños de niveles educativos 4, 5 y 6, es decir, de 3 a 6 años) y, por último, Grupo 3 (niños de niveles educativos 7 y 8, es decir, de 6 a 8 años).

La primera versión de ChildCIdb_v1 se ha dividido en conjuntos de datos de desarrollo (80 %) y de evaluación (20 %), que comprenden grupos separados de sujetos. El conjunto de datos de desarrollo se utiliza para entrenar los sistemas de detección de grupos de edad, mientras que el conjunto de datos de evaluación se utiliza finalmente para probar los sistemas entrenados en condiciones realistas (nuevos sujetos no vistos durante la etapa de desarrollo). Como el número de muestras disponibles en los grupos 1 y 3 es menor que en el grupo 2, la técnica de aumento de datos SMOTE de la librería Imbalanced-Learn ToolBox¹ se consideró sólo durante la etapa de desarrollo para equilibrar y entrenar mejor los modelos. Para la evaluación final, sólo se consideran muestras reales de ChildCIdb. Para estimar mejor la destreza de los modelos de aprendizaje automático propuestos, en este marco experimental se utiliza validación cruzada *k-fold* con $k=5$. Los resultados finales proporcionan los valores medios de la validación cruzada de 5 *fold*.

¹<https://imbalanced-learn.org/stable/>

5.2. Evaluación de los Resultados

En esta sección se analizan los resultados obtenidos, siempre en términos de *Accuracy (Acc.)*, para las diferentes evaluaciones realizadas sobre cada uno de los tests de ChildCI de forma individual con el objetivo de detectar correctamente el grupo de edad de los niños teniendo en cuenta: *i)* los conjuntos de características descritos en la sección 4.3.1, *ii)* los algoritmos de selección de características descritos en la sección 4.3.2 y los algoritmos de clasificación presentados en la sección 4.3.3.

Además, para ofrecer una información más completa, se ha utilizado un popular y novedoso método de visualización de datos para mostrar las distribuciones de las características entre los grupos de edad. Para cada test, utilizando el mejor subconjunto de características seleccionado mediante las técnicas presentadas en la sección 4.3.2, se muestran las proyecciones en 2D de cada uno de los niños considerados en ChildCIdb_v1 mediante el algoritmo *Uniform Manifold Approximation and Projection (UMAP)* [61]. Cada punto ha sido coloreado según su grupo de edad de referencia, permitiendo visualizar para todos los tests 3 *clusters* altamente correlacionados con los grupos de edad.

5.2.1. Test 1: Tap and Reaction Time

5.2.1.1. Resultados

En la tabla 5.1 se pueden observar los resultados obtenidos en términos de Acc. para la clasificación por grupos de edad (%) sobre el conjunto de datos de evaluación final de ChildCIdb_v1, referido al test de “*Tap and Reaction Time*” y utilizando los diferentes enfoques de selección de características (SFFS y GA) y clasificación (SVM y *Random Forest*) considerados.

Es destacable mencionar que el algoritmo SFFS es el que proporciona los mejores resultados con un Acc. medio del 88.78 % frente al 86.75 % de GA. Si analizamos los resultados de forma individual, SVM es el clasificador que mejor funciona tanto si utilizamos como selector de características SFFS o GA. El mejor resultado se obtiene de la combinación de SFFS + SVM, alcanzando un Acc. del 89.79 %.

5.2.1.2. Análisis de Características

Si nos centramos en analizar que tipos de características han sido los más seleccionados del conjunto de 190 características globales inicial, generado y presentado en 4.3.1, en la figura 5.1 se pueden observar dos gráficos: *i)* a la izquierda, un gráfico circular mostrando el porcentaje medio de características seleccionadas por categoría, es decir, *Time*, *Kinematic*, *Direction*, *Geometry*, *Drawing*, *Spiral*, *Drag and Drop* y *Tap* 4.1, *ii)* a la derecha, una proyección en 2D de las mejores características seleccionadas para el test “*Tap and Reaction Time*” utilizando UMAP.

En la parte izquierda de la figura 5.1, se puede observar como el nuevo conjunto de características diseñadas para este test no tiene gran relevancia en la tarea de detección de los grupos de edad, ya que del total de características seleccionadas sólo el 1.7 % son de este tipo. Sin embargo, se puede observar como el resto de características diseñadas en este TFM para otros tests (*Drawing + Spiral + Drag and Drop*) si tienen un gran impacto si las analizamos en conjunto, sumando el 50.6 % de las características seleccionadas. Si nos centramos en la parte derecha de la figura 5.1 podemos observar en el gráfico UMAP la existencia de 3 *clusters* aunque la separabilidad entre ellos no es perfecta, lo que concuerda con el 89.79 % de Acc. obtenido para este test mediante SFFS + SVM.

Feature Selection	SVM	Random Forest
SFFS	89.79	87.71
GA	88.51	85.00

Tabla 5.1: Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “**Tap and Reaction Time**” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.




Figura 5.1: Gráficos de las mejores características seleccionadas en la sección 5.2.1. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “**Tap and Reaction Time**” en el espacio 2D generado mediante UMAP (SFFS + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.

Feature Selection	SVM	Random Forest
SFFS	87.23	83.89
GA	85.47	83.09

Tabla 5.2: Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “**Drag and Drop**” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.




Figura 5.2: Gráficos de las mejores características seleccionadas en la sección 5.2.2. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “**Drag and Drop**” en el espacio 2D generado mediante UMAP (SFFS + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.

5.2.2. Test 2: Drag and Drop

5.2.2.1. Resultados

En la tabla 5.2 es posible observar los resultados obtenidos en términos de Acc. para la clasificación por grupos de edad (%) sobre el conjunto de datos de evaluación final de ChildCIdb_v1, referido al test de “*Drag and Drop*” y utilizando los diferentes enfoques de selección de características (SFFS y GA) y clasificación (SVM y *Random Forest*) considerados.

Si nos fijamos en los valores de la tabla 5.2 podemos observar que, al igual que en el test de “*Tap and Reaction Time*”, la combinación de SFFS + SVM, como selector de características y clasificador respectivamente, es la que mejor resultado da con un Acc. del 87.23 %. Sin embargo, en este caso SFFS no siempre obtiene el mejor resultado independientemente de si utiliza como clasificador SVM o *Random Forest*. En esta ocasión, utilizar el clasificador SVM combinado con cualquiera de los dos selectores de características da siempre mejores resultados que utilizar *Random Forest*.

5.2.2.2. Análisis de Características

Si analizamos que tipos de características han sido los más seleccionados del conjunto de 185 características globales inicial, generado y presentado en 4.3.1, en la figura 5.2 se pueden observar dos gráficos: *i*) a la izquierda, un gráfico circular mostrando el porcentaje medio de características seleccionadas por categoría, es decir, *Time*, *Kinematic*, *Direction*, *Geometry*, *Drawing*, *Spiral*, y *Drag and Drop* 4.1, *ii*) a la derecha, una proyección en 2D de las mejores características seleccionadas para el test “*Drag and Drop*” utilizando UMAP.

Si nos centramos en la parte derecha de la figura 5.2 podemos ver en el gráfico UMAP la existencia de 3 *clusters* con una separabilidad entre ellos considerablemente buena, lo que contrasta con el 87.23 % de Acc. obtenido en este test mediante SFFS + SVM. Por otro lado, en la parte izquierda de la figura se puede observar como en este caso el nuevo conjunto de características diseñado específicamente para esta tarea tiene un gran impacto en la tarea de detección de los grupos de edad asociados a los niños, siendo de este tipo el 17.5 % de las características seleccionadas. Además, la combinación de este tipo de características con otras de tipo *Spiral* y *Drawing*, también ideadas en este TFM, tienen un mayor impacto, alcanzando el 47.7 % del total de características seleccionadas. Características de otros tipos como *Geometry* tienen también un gran factor de importancia para este test, siendo un 19.1 % las características seleccionadas de este tipo.

5.2.3. Test 3: Zoom-in

5.2.3.1. Resultados

La tabla 5.3 muestra los resultados obtenidos en términos de Acc. para la clasificación por grupos de edad (%) sobre el conjunto de datos de evaluación final de ChildCIdb_v1, referido al test de “*Zoom-in*” y utilizando los diferentes enfoques de selección de características (SFFS y GA) y clasificación (SVM y *Random Forest*) considerados.

En los valores reflejados en la tabla 5.3 podemos observar como para este test la mejor combinación de selector de características y clasificador se da en el caso de GA + SVM, alcanzando un Acc. del 81.33 %. De nuevo utilizando SVM obtenemos mejores resultados que con *Random Forest* independientemente del selector de características que se utilice. Con SFFS + SVM obtenemos resultados muy similares llegando al 80.22 % de Acc.

Feature Selection	SVM	Random Forest
SFFS	80.22	78.14
GA	81.33	78.15

Tabla 5.3: Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “**Zoom-in**” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.




Figura 5.3: Gráficos de las mejores características seleccionadas en la sección 5.2.3. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “**Zoom-in**” en el espacio 2D generado mediante UMAP (GA + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.

Feature Selection	SVM	Random Forest
SFFS	79.74	79.26
GA	82.45	80.22

Tabla 5.4: Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “**Zoom-out**” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.




Figura 5.4: Gráficos de las mejores características seleccionadas en la sección 5.2.4. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “**Zoom-out**” en el espacio 2D generado mediante UMAP (GA + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.

5.2.3.2. Análisis de Características

Analizando que tipos de características han sido los más seleccionados del conjunto de 35 características globales inicial, generado y presentado en 4.3.1. Para este test las características analizadas han sido de tipo *Time*, *Geometry*, *Drawing*, *Zoom*, y *Spiral* 4.1.

Centrándonos en la parte izquierda de la figura 5.3 se puede ver como para este test el conjunto de características específicamente diseñado tiene un gran peso en la tarea de detección de los grupos de edad asociados a los niños, siendo el 69.2 % de las características seleccionadas de este tipo junto con el 21.8 % del tipo *Drawing*. Además, cabe destacar que ninguna característica de tipo *Geometry* ha sido seleccionada para este test. Por otro lado, si analizamos el gráfico UMAP en la parte derecha de la figura 5.3, podemos visualizar la existencia de 3 *clusters* bastante bien separados, lo que indica que el conjunto de características seleccionado para detectar los diferentes grupos de edad entre los niños en este test es discriminativo.

5.2.4. Test 4: Zoom-out

5.2.4.1. Resultados

Si analizamos el contenido de la tabla 5.4 podremos encontrar los resultados obtenidos en términos de Acc. para la clasificación por grupos de edad (%) sobre el conjunto de datos de evaluación final de ChildCIdb_v1, referido al test de “*Zoom-out*” y utilizando los diferentes enfoques de selección de características (SFFS y GA) y clasificación (SVM y *Random Forest*) considerados.

Debido a que este test es muy similar al test “*Zoom-in*” analizado anteriormente, los valores mostrados en la tabla 5.4 reflejan que la mejor combinación de selector de características y clasificador vuelve a ser de nuevo GA + SVM, alcanzando un Acc. del 82.45 %. Sin embargo, en este caso utilizar SVM no siempre es la mejor opción ya que combinar GA + *Random Forest* (80.22 %) nos otorga mejores resultados que combinar SFFS + SVM (79.74 %).

5.2.4.2. Análisis de Características

Si nos centramos en analizar que tipos de características han sido los más seleccionados del conjunto de 35 características globales inicial, generado y presentado en 4.3.1. Diversos tipos de características han sido analizados durante el estudio realizado sobre este test: *Time*, *Geometry*, *Drawing*, *Zoom*, y *Spiral* 4.1.

Analizando la figura 5.4, en la parte izquierda se puede observar como para este test, y al igual que para el anterior (*Zoom-in*), el conjunto de características específicamente diseñado vuelve a tener un gran peso en la tarea de detección de los grupos de edad asociados a los niños, siendo el 62.2 % de las características seleccionadas de este tipo y de nuevo junto con las de tipo *Drawing* con el 27.1 %. Analizando la parte derecha de la figura 5.4, en el gráfico UMAP volvemos a ver la existencia de 3 *clusters* con una separación similar a la analizada anteriormente en la figura 5.3.

5.2.5. Test 5: Spiral Test

5.2.5.1. Resultados

Para este test en la tabla 5.5 se pueden ver los resultados obtenidos en términos de Acc. para la clasificación por grupos de edad (%) sobre el conjunto de datos de evaluación final de

Feature Selection	SVM	Random Forest
FFFS	88.67	82.93
GA	85.16	81.33

Tabla 5.5: Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “**Spiral Test**” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.




Figura 5.5: Gráficos de las mejores características seleccionadas en la sección 5.2.5. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “**Spiral Test**” en el espacio 2D generado mediante UMAP (FFFS + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.

Feature Selection	Naive Bayes	Logistic Regression	K-NN	Random Forest	AdaBoost	SVM	MLP
FDR	69.63	73.99	71.24	75.56	68.27	75.58	76.72
FFFS	78.09	82.22	81.98	88.69	76.28	90.45	85.98
GA	77.86	81.30	77.86	80.37	73.98	81.51	81.76

Tabla 5.6: Resultados obtenidos en términos de Acc. (%) por grupos de edad en el test “**Drawing Test**” para los diferentes enfoques de selección de características y clasificación considerados. Destacamos en verde el mejor resultado obtenido.




Figura 5.6: Gráficos de las mejores características seleccionadas en la sección 5.2.6. (a) Gráfico circular con el porcentaje medio de características seleccionadas por categoría. (b) Proyección de las mejores características seleccionadas para el test “**Drawing Test**” en el espacio 2D generado mediante UMAP (FFFS + SVM) donde cada punto corresponde a un niño de ChildCIdb_v1.

ChildCIdb_v1, referido al test de “*Spiral Test*” y utilizando los diferentes enfoques de selección de características (SFFS y GA) y clasificación (SVM y *Random Forest*) considerados.

Estos valores reflejados en la tabla 5.5 nos indican que SVM es el clasificador que mejor funciona para este test en la tarea de detección del grupo de edad de los niños. El mejor resultado en términos de Acc. se produce al combinar SFFS + SVM, alcanzando un 88.67 %. Por otro lado, combinando GA + SVM también se obtiene un buen resultado (85.16 %) y, aunque es mejor que los dos logrados con *Random Forest*, no consigue superar a la combinación de SFFS + SVM. Como información adicional, la figura 5.7 muestra algunos ejemplos de la realización de este test por parte de niños pertenecientes a diferentes grupos de edad.

5.2.5.2. Análisis de Características

Centrándonos en el análisis de que tipos de características han sido los más seleccionados del conjunto de 172 características globales inicial, generado y presentado en 4.3.1, en la figura 5.5 se pueden observar dos gráficos: *i)* a la izquierda, un gráfico circular mostrando el porcentaje medio de características seleccionadas por categoría, es decir, *Time*, *Kinematic*, *Direction*, *Geometry*, *Pressure*, *Drawing* y *Spiral* 4.1, *ii)* a la derecha, una proyección en 2D de las mejores características seleccionadas para el test “*Spiral Test*” utilizando UMAP.

Si analizamos la figura 5.5, en la parte izquierda se puede observar el conjunto de características específicamente diseñado para este test juega un papel importante a la hora de obtener buenos resultados en la tarea de detección del grupo de edad de los niños. Esto se debe a que el 14.9 % de las características seleccionadas en este test son de tipo *Spiral*. También existen otros tipos de características como *Drawing* (23.5 %), *Geometry* (15.4 %), *Time* (15.3 %) y *Kinematic* (16.0 %) que también son muy importantes debido a sus altos porcentajes de selección. Por otro lado, si nos fijamos en la parte derecha de la figura 5.5 de nuevo es posible observar 3 *clusters* bien separados entre sí, lo que a su vez concuerda con el 88.67 % de Acc. obtenido en la combinación de SFFS + SVM.

5.2.6. Test 6: Drawing Test

A diferencia con los test analizados en los apartados anteriores, para este test en concreto, todos los selectores de características y clasificadores, presentados en 4.3.2 y 4.3.3 respectivamente, han sido utilizados debido a que fue el test sobre el que se realizó el primer análisis inicial. Por tanto, el que en el resto de tests solo hayan sido considerados SFFS y GA como selectores de características y *Random Forest* y SVM como clasificadores, es debido a que fueron aquellos enfoques en los que se obtuvieron mejores resultados durante el análisis del test “*Drawing Test*”.

5.2.6.1. Resultados

La tabla 5.6 muestra los resultados obtenidos en términos de Acc. para la clasificación por grupos de edad (%) sobre el conjunto de datos de evaluación final de ChildCIdb_v1, referido al test de dibujar el árbol y utilizando los diferentes enfoques de selección de características y clasificación considerados.

En primer lugar, se analizan los resultados obtenidos por cada técnica de selección de características. Como se puede observar, el algoritmo SFFS proporciona los mejores resultados en todos los casos (83,38 % de Acc. medio), seguido del Algoritmo Genético (79.23 % de Acc. medio). El algoritmo FDR proporciona los peores resultados de Acc. medio (73.00 %). Esto parece

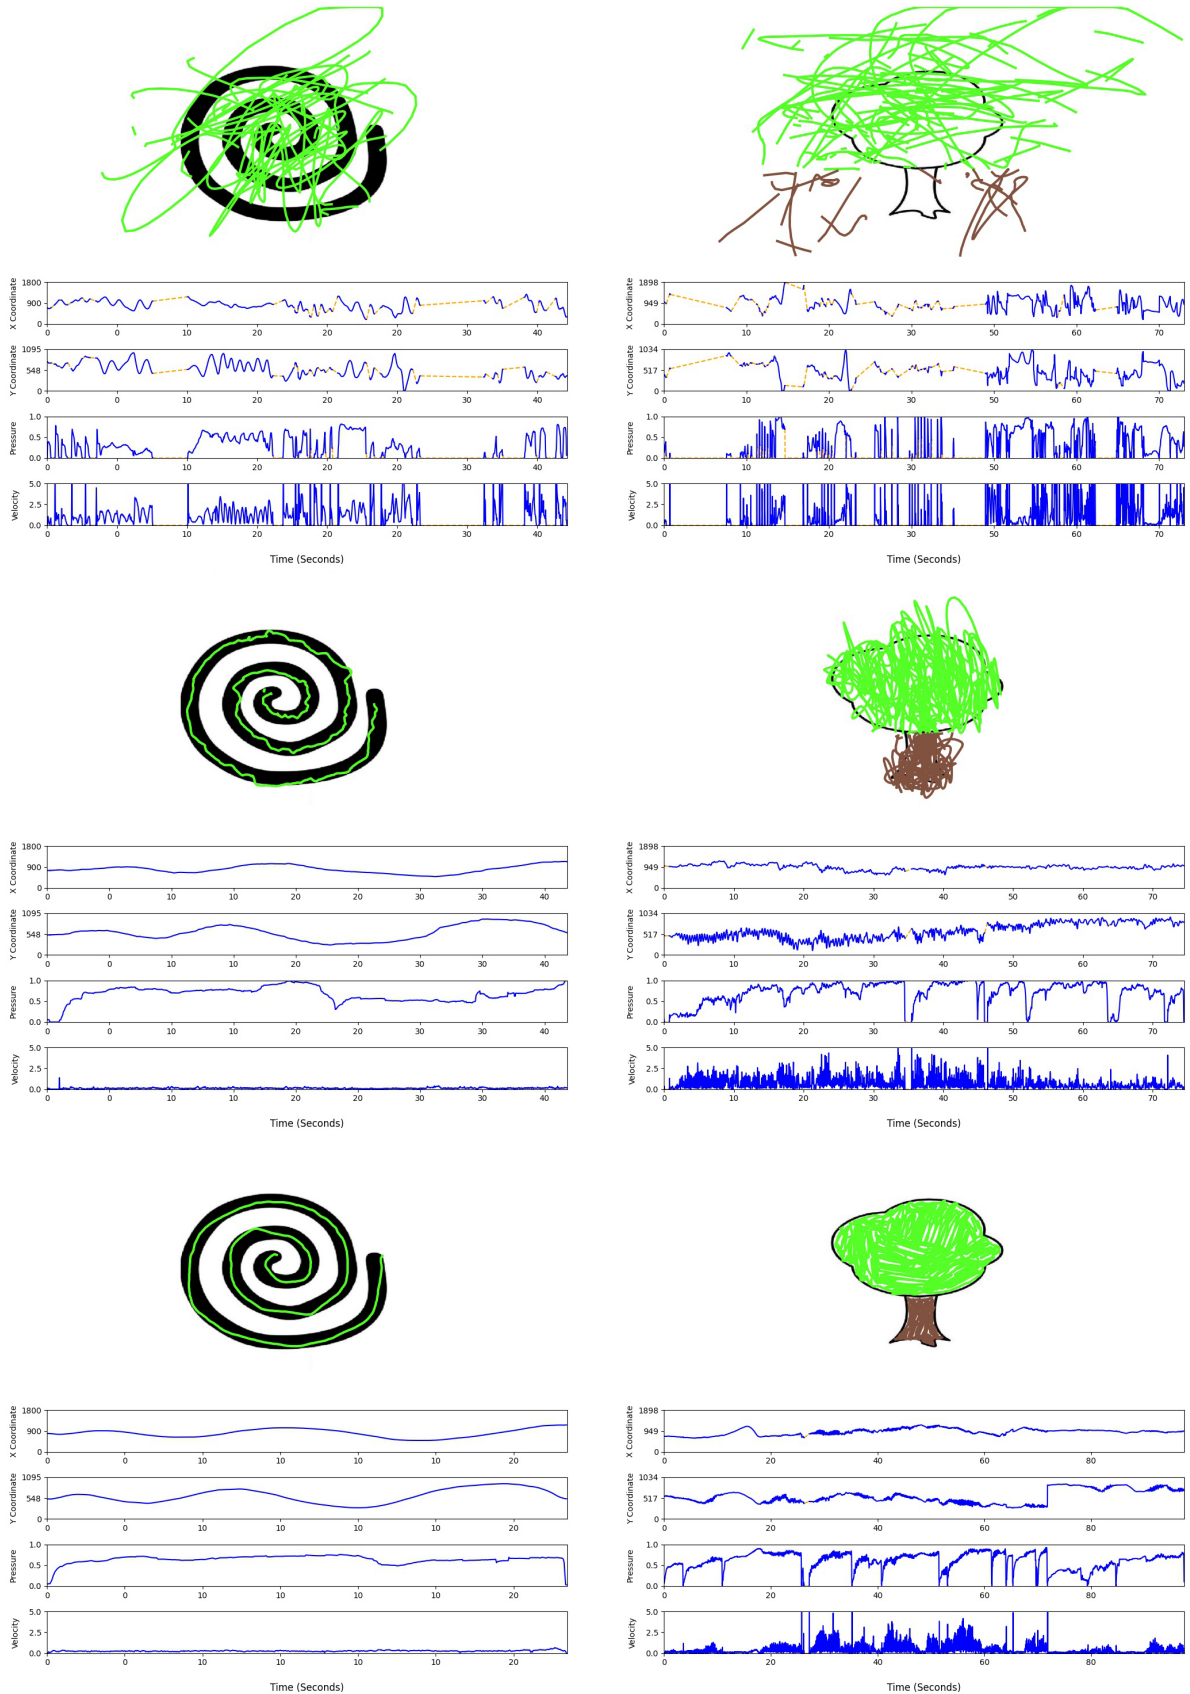


Figura 5.7: Ejemplos de “Spiral Test” y de “Drawing Test” realizados por tres grupos de edad de niños diferentes: (arriba) de 1 a 3 años, (en medio) de 3 a 6 años y (abajo) de 6 a 8 años.

$$C_{n,x} = \binom{n}{x} = \frac{n!}{x!(n-x)!} \quad (5.1)$$

Equation 5.1: Fórmula de combinatoria sin repetición donde n = número de observaciones totales y x = número de elementos seleccionados.

producirse porque la técnica de selección de características FDR se basa en el poder discriminatorio de cada característica independiente. En el proceso de selección no se tienen en cuenta las correlaciones entre las características.

Analizando los resultados obtenidos por cada clasificador, SVM, Random Forest y MLP proporcionan los mejores resultados con un 90.45 %, 88.69 % y 85.98 % de Acc., respectivamente. Otros clasificadores más sencillos, como Naive Bayes y K-NN, ofrecen resultados mucho peores (69.63 % y 71.24 % de Acc.). Por tanto, para este test podemos asegurar que el clasificador que mejor comportamiento tiene es SVM. Como información adicional, la figura 5.7 muestra algunos ejemplos de la realización de este test por parte de niños pertenecientes a diferentes grupos de edad.

5.2.6.2. Análisis de Características

En esta sección se analiza el tipo de características seleccionadas por los enfoques de aprendizaje automático estudiados en el apartado anterior. En la figura 5.6 podemos observar dos gráficos: *i)* a la izquierda, un gráfico circular mostrando el porcentaje medio de características seleccionadas por categoría, es decir, *Time*, *Kinematic*, *Direction*, *Geometry*, *Pressure* y *Drawing* 4.1, *ii)* a la derecha, una proyección en 2D de las mejores características seleccionadas para el test “*Drawing Test*” utilizando UMAP.

En la parte izquierda de la figura 5.6, en general podemos ver que las características novedosas relacionadas con la información del test “*Drawing Test*” son las más seleccionadas con una media del 24.2 % sobre el conjunto total de las 148 características globales generado inicialmente y presentado en la sección 4.3.1. Este resultado demuestra el éxito de las características novedosas diseñadas para este test en la tarea de detección de grupos de edad de niños. Otras características basadas en la información de tipo *Geometry* (20.3 %) y *Kinematic* (18.5 %) son también muy importantes para distinguir entre diferentes grupos de edad. Además, podemos observar en el gráfico UMAP de la parte derecha de la figura 5.6 la existencia clara de 3 *clusters* separados entre ellos. Esto demuestra que la calidad de las características seleccionadas concuerda con los resultados obtenidos en términos de Acc.

5.3. Combinación de los Métodos de Clasificación

En este apartado se ha seleccionado para cada test aquel clasificador que obtuvo el mejor resultado en la tarea de detección del grupo de edad de los niños con el objetivo de combinar dichos resultados para analizar el potencial de los tests de forma conjunta. En total existen 6 tests, por tanto tenemos 6 modelos de clasificación previamente entrenados, uno para cada test. El problema aquí reside en cómo realizar la combinación, es decir, ¿qué resultados de qué tests debemos combinar para obtener el mejor rendimiento en la tarea de detección del grupo de edad?.

Para ello, mediante operaciones de combinatoria básicas (ver fórmula 5.1), se ha calculado el número de combinaciones sin repetición agrupando los tests entre ellos de todas las formas posibles. Es decir, se han combinado los resultados obtenidos de cada test agrupando dichos

Tap and Reaction Time	Drag and Drop	Zoom In	Zoom Out	Spiral Test	Drawing Test	Accuracy
✓	✓					86.51
✓		✓				87.3
✓			✓			83.33
✓				✓		88.89
✓					✓	85.71
	✓	✓				85.71
	✓		✓			81.75
	✓			✓		85.71
	✓				✓	87.3
		✓	✓			81.75
		✓		✓		88.1
		✓			✓	87.3
			✓	✓		86.51
			✓		✓	85.71
				✓	✓	92.86

Tabla 5.7: Resultados en términos de Acc. de las 15 posibles combinaciones sin repetición, en grupos de 2 ($C_{6,2}$), de los diferentes tests de ChildCI. Destacamos en verde el mejor resultado obtenido.

Tap and Reaction Time	Drag and Drop	Zoom In	Zoom Out	Spiral Test	Drawing Test	Accuracy
✓	✓	✓				86.51
✓	✓		✓			85.71
✓	✓			✓		91.27
✓	✓				✓	88.1
✓		✓	✓			87.3
✓		✓		✓		88.89
✓		✓			✓	87.3
✓			✓	✓		87.3
✓			✓		✓	88.1
✓				✓	✓	91.27
	✓	✓	✓			84.13
	✓	✓		✓		89.68
	✓	✓			✓	87.3
	✓		✓	✓		86.51
	✓		✓		✓	87.3
	✓			✓	✓	93.65
		✓	✓	✓		88.1
		✓	✓		✓	86.51
		✓		✓	✓	88.1
			✓	✓	✓	89.68

Tabla 5.8: Resultados en términos de Acc. de las 20 posibles combinaciones sin repetición, en grupos de 3 ($C_{6,3}$), de los diferentes tests de ChildCI. Destacamos en verde el mejor resultado obtenido.

Tap and Reaction Time	Drag and Drop	Zoom In	Zoom Out	Spiral Test	Drawing Test	Accuracy
✓	✓	✓	✓			87.3
✓	✓	✓		✓		92.06
✓	✓	✓			✓	88.89
✓	✓		✓	✓		88.1
✓	✓		✓		✓	88.1
✓	✓			✓	✓	90.48
✓		✓	✓	✓		89.68
✓		✓	✓		✓	88.1
✓		✓		✓	✓	89.68
✓			✓	✓	✓	88.89
	✓	✓	✓	✓		87.3
	✓	✓	✓		✓	88.89
	✓	✓		✓	✓	91.27
	✓		✓	✓	✓	88.89
		✓	✓	✓	✓	89.68

Tabla 5.9: Resultados en términos de Acc. de las 15 posibles combinaciones sin repetición, en grupos de 4 ($C_{6,4}$), de los diferentes tests de ChildCI. Destacamos en verde el mejor resultado obtenido.

Tap and Reaction Time	Drag and Drop	Zoom In	Zoom Out	Spiral Test	Drawing Test	Accuracy
✓	✓	✓	✓	✓		89.68
✓	✓	✓	✓		✓	88.89
✓	✓	✓		✓	✓	90.48
✓	✓		✓	✓	✓	88.1
✓		✓	✓	✓	✓	88.89
	✓	✓	✓	✓	✓	91.27

Tabla 5.10: Resultados en términos de Acc. de las 6 posibles combinaciones sin repetición, en grupos de 5 ($C_{6,5}$), de los diferentes tests de ChildCI. Destacamos en verde el mejor resultado obtenido.

Tap and Reaction Time	Drag and Drop	Zoom In	Zoom Out	Spiral Test	Drawing Test	Accuracy
✓	✓	✓	✓	✓	✓	89.68

Tabla 5.11: Resultados en términos de Acc. de las posibles combinaciones sin repetición, en grupos de 6 ($C_{6,6}$), de los diferentes tests de ChildCI.

tests en grupos de 2, 3, 4, 5 y 6 (todos juntos). En total existen 57 combinaciones posibles: *i)* 15 combinaciones en grupos de 2, *ii)* 20 combinaciones en grupos de 3, *iii)* 15 combinaciones en grupos de 4, *iv)* 6 combinaciones en grupos de 5 y *v)* 1 combinación en grupos de 6.

Cada uno de los modelos de aprendizaje automático entrenados durante la fase de desarrollo genera un conjunto de 3 probabilidades, cuya suma no puede ser mayor que 1, a la hora de predecir a que grupo de edad pertenece un niño. Es decir, calcula la probabilidad (valor comprendido entre 0 y 1) de que un niño pertenezca al grupo 1, al grupo 2 y al grupo 3, siendo el valor más alto el que determina el grupo de edad al que pertenece el niño según el clasificador. Por tanto, para realizar la combinación de los resultados, se calcula una media de las probabilidades generadas para cada conjunto de tests agrupados, siendo de nuevo el valor más alto el que determina el grupo de edad asociado al niño.

Si nos centramos en los resultados obtenidos para combinaciones de test de dos en dos, en la tabla 5.7 podemos ver los resultados en términos de Acc. (%) para las 15 combinaciones posibles. El mejor resultado se produce de la combinación de los tests “*Spiral Test*” y “*Drawing Test*”, alcanzando el 92.86 %. Respecto a las agrupaciones de tres en tres, en la tabla 5.8 se puede observar que el mejor resultado obtenido para las 20 combinaciones posibles es el logrado de la combinación de los tests “*Drag and Drop*”, “*Spiral Test*” y “*Drawing Test*” con un 93.65 % de Acc., siendo este el mejor resultado obtenido durante todos los experimentos realizados en el presente TFM para la tarea de detección del grupo de edad asociado a los niños.

Por otro lado, están las combinaciones realizadas de cuatro en cuatro. Agrupando los tests de esta forma existen 15 combinaciones posibles. La mejor combinación se produce al agrupar los tests “*Tap and Reaction Time*”, “*Drag and Drop*”, “*Zoom-in*” y “*Spiral Test*” como se puede observar en la tabla 5.9, donde se logra un Acc. del 92.06 %. Los resultados para las combinaciones de tests agrupados de cinco en cinco pueden verse en la tabla 5.10, donde en el mejor de los casos se alcanza un 91.27 % de Acc. tras la combinación de los tests “*Drag and Drop*”, “*Zoom-in*”, “*Zoom-out*”, “*Spiral Test*” y “*Drawing Test*”. Por último, si nos referimos a la agrupación de todos los tests de ChildCI, en la tabla 5.11 podemos observar que el resultado de dicha combinación produce un Acc. del 89.68 %, lo que indica que aunque a primera vista combinar todos los tests para conseguir un mejor resultado puede parecer la mejor opción no necesariamente tiene por qué serla.

Por consiguiente, podemos asegurar que realizar una combinación de los diferentes test con el fin de obtener mejores resultados es una buena práctica, debido a que tras la combinación de los tests “*Drag and Drop*”, “*Spiral Test*” y “*Drawing Test*” se alcanza un mejor resultado (93.65 % de Acc.) que el obtenido en el mejor de los casos para el análisis individual de cada test (90.45 % de Acc. en el análisis del test “*Drawing Test*”).

6

Conclusiones y Trabajo Futuro

6.1. Conclusiones

En este TFM se ha presentado un estudio preliminar del proyecto ChildCI, cuyo objetivo es generar una mejor comprensión de las Interacciones Niño-Ordenador con aplicaciones a la *e-Health* y al *e-Learning*, entre otras. En particular, en este TFM se han presentado todos los detalles relativos al diseño y desarrollo de una nueva aplicación móvil infantil, el protocolo de adquisición específico considerado y las dos primeras sesiones de captura del conjunto de datos ChildCI (ChildCIdb_v1 y ChildCIdb_v2), que están disponibles públicamente para fines de investigación. En el escenario considerado, los niños interactúan con un dispositivo *tablet*, utilizando tanto el lápiz óptico como el dedo, realizando diferentes tareas que requieren distintos niveles de habilidades motoras y cognitivas. ChildCIdb está compuesto por más de 400 niños con edades comprendidas entre los 18 meses y los 8 años, considerando por tanto las tres primeras etapas del desarrollo motor y cognitivo de la teoría de Piaget [8].

Además, ha sido demostrado el potencial de ChildCIdb incluyendo resultados experimentales para una de las muchas aplicaciones posibles: la detección del grupo de edad de los niños. Se han estudiado diferentes enfoques de aprendizaje automático, proponiendo nuevos conjuntos de características globales para cada uno de los tests con el objetivo de detectar automáticamente el grupo de edad, logrando resultados de precisión superiores al 90 % y hallazgos interesantes en cuanto al tipo de características más útiles.

Por último, si comparamos los resultados obtenidos con el estado del arte, hasta donde sabemos, este es el primer estudio que se centra en la clasificación de grupos de edad de niños (de 18 meses a 8 años) en función de la interacción con dispositivos móviles. Los estudios anteriores se centraron en una tarea más sencilla, es decir, la clasificación entre niños (3-6 años) y adultos [9, 11, 12], logrando en los mejores casos resultados de precisión de clasificación del 96,3 %. Comparando ese resultado obtenido en una tarea más sencilla con los resultados obtenidos en el presente TFM (resultados de precisión superiores al 90 %), podemos concluir que: *i)* se consiguen buenos resultados, demostrando la solidez de los sistemas de clasificación por grupos de edad propuestos, y *ii)* la posibilidad de distinguir con resultados de alta precisión entre diferentes

grupos de edad de los niños. Todo esto demuestra la existencia de diferentes patrones en el proceso de control motor de los niños con la edad, como por ejemplo la velocidad y la aceleración al realizar trazos con el lápiz óptico.

6.2. Limitaciones y Trabajo Futuro

Algunos aspectos dentro del proyecto ChildCI son mejorables. En particular, la correlación de la información extraída de nuestro estudio con otras pruebas estándar populares consideradas para el desarrollo de los niños, como la herramientas: *NIH Toolbox*¹, *Bayley Scales of Infant and Toddler Development* [62] y *Mullen Scales of Early Learning* [63]. Este aspecto podría beneficiar aún más los conocimientos extraídos en este TFM, y al mismo tiempo mejorar esas pruebas populares con medidas más cuantitativas de la evolución motora y cognitiva de los niños. Este aspecto se considerará en las siguientes adquisiciones de ChildCIdb. Además, el trabajo futuro estará orientado a *i)* ampliar ChildCIdb con más participantes y sesiones de adquisición, *ii)* analizar y mejorar la precisión de los sistemas de detección de grupos de edad de los niños utilizando técnicas más sofisticadas, *iii)* estudiar la aplicación de otras representaciones de rasgos y señales del dibujo y la interacción con la pantalla más allá de las probadas aquí con especial énfasis en los recientes métodos de *Deep Learning* [64, 65], *iv)* desarrollar modelos de interacción independientes del niño para los diferentes tests de los que se puedan derivar comportamientos dependientes del niño [66], *v)* correlacionar la información de interacción con los metadatos almacenados en la base de datos como los resultados académicos en el aprendizaje y el TDAH [67], *vi)* combinar la información proporcionada por los diferentes tests utilizando métodos de fusión de información [68], y *vii)* explotar ChildCIdb en otros problemas de investigación en torno al *e-Learning* [47] y la *e-Health* [46], [69].

¹<https://www.nia.nih.gov/research/resource/nih-toolbox>

Glosario de acrónimos

- **e-Learning**: Electronic Learning
- **CCI**: *Child-Computer Interaction* o Interacción Niño-Ordenador
- **TFM**: Trabajo de Fin de Máster
- **ChildCI**: Child-Computer Interaction
- **ChildCIdb**: Child-Computer Interaction DataBase
- **DGBL**: Digital Game-Based Learning o Aprendizaje Basado en Juegos Digitales
- **TDAA**: Trastorno por Deficit de Atención/Hiperactividad
- **PST**: Pen Stroke Test
- **AUC**: Area Under the Curve o Area Bajo la Curva
- **e-Health**: Electronic Health
- **NB**: Naive Bayes
- **LR**: Logistic Regression
- **K-NN**: K-Nearest Neighbours
- **RF**: Random Forest
- **AB**: AdaBoost
- **SVM**: Support Vector Machines
- **MLP**: Multi-Layer Perceptron
- **ANN**: Artificial Neural Network o Red Neuronal Artificial
- **HCI**: Human-Computer Interaction

Bibliografía

- [1] Jenny Stillwaggon Radesky and Dimitri Alexander Christakis. Increased Screen Time: Implications for Early Childhood Development and Behavior. *Pediatric Clinics of North America*, 63(5):827–839, 2016.
- [2] Ahmet Osman Kilic, Eyup Sari, Husniye Yucel, Melahat Melek Ouguz, Emine Polat, Esma Altinel Acoglu, and Saliha Senel. Exposure to and Use of Mobile Devices in Children Aged 1-60 Months. *European Journal of Pediatrics*, 178(2):221–227, 2019.
- [3] Natalia Kucirkova, Cecilie Evertsen-Stanghelle, Ingunn Studsrød, Ida Bruheim Jensen, and Ingunn Størksen. Lessons for Child-Computer Interaction Studies Following the Research Challenges During the COVID-19 Pandemic. *International Journal of Child-Computer Interaction*, page 100203, 2020.
- [4] Alissa N. Antle and Christopher Frauenberger. Child-Computer Interaction in Times of a Pandemic. *International Journal of Child-Computer Interaction*, page 100201, 2020.
- [5] Wolmet Barendregt, Olof Torgersson, Eva Eriksson, and Peter Börjesson. Intermediate-Level Knowledge in Child-Computer Interaction: A Call for Action. In *Proceedings of the 2017 Conference on Interaction Design and Children*, IDC '17, pages 7–16, New York, NY, USA, 2017. Association for Computing Machinery.
- [6] Damyanka Tsvyatkova and Cristiano Storni. A review of selected methods, techniques and tools in Child-Computer Interaction (CCI) developed/adapted to support children’s involvement in technology development. *International Journal of Child-Computer Interaction*, 22:100148, 2019.
- [7] Ruben Tolosana, Juan Carlos Ruiz-Garcia, Ruben Vera-Rodriguez, Jaime Herreros-Rodriguez, Sergio Romero-Tapiador, Aythami Morales, and Julian Fierrez. Child-Computer Interaction: Recent Works, New Dataset, and Age Detection. <https://arxiv.org/abs/2102.01405>, Feb 2021.
- [8] Jean Piaget and Barbel Inhelder. *The Psychology of the Child*. Basic books, 2008.
- [9] Radu-Daniel Vatavu, Lisa Anthony, and Quincy Brown. Child or Adult? Inferring Smartphone Users’ Age Group from Touch Measurements Alone. In *Proc. Conference on Human-Computer Interaction*, 2015.
- [10] Lisa Anthony, Kathryn A Stofer, Annie Luc, and Jacob O Wobbrock. Gestures by Children and Adults on Touch Tables and Touch Walls in a Public Science Center. In *Proc. International Conference on Interaction Design and Children*, 2016.
- [11] Ruben Vera-Rodriguez, Ruben Tolosana, Javier Hernandez-Ortega, Alejandro Acien, Aythami Morales, Julian Fierrez, and Javier Ortega-Garcia. Modeling the Complexity of Signature and Touch-Screen Biometrics using the Lognormality Principle. In Rejean Plamondon, Angelo Marcelli, and Miguel A Ferrer, editors, *The Lognormality Principle and its Applications*. World Scientific, 2020.

- [12] Alejandro Acien, Aythami Morales, Julian Fierrez, Ruben Vera-Rodriguez, and Javier Hernandez-Ortega. Active detection of age groups based on touch interaction. *IET Biometrics*, 8(1):101–108, 2019.
- [13] Lorna McKnight and Brendan Cassidy. Children’s Interaction with Mobile Touch-Screen Devices: Experiences and Guidelines for Design. *International Journal of Mobile Human Computer Interaction*, 2(2):1–18, 2010.
- [14] Lisa Anthony, Quincy Brown, Berthel Tate, Jaye Nias, Robin Brewer, and Germaine Irwin. Designing Smarter Touch-Based Interfaces for Educational Contexts. *Personal and Ubiquitous Computing*, 18(6):1471–1483, 2014.
- [15] Radu-Daniel Vatavu, Gabriel Cramariuc, and Doina Maria Schipor. Touch interaction for children aged 3 to 6 years: Experimental findings and relationship to motor skills. *International Journal of Human-Computer Studies*, 74:54–76, 2015.
- [16] Lucrezia Crescenzi Lanna and Mariona Grané Oro. Touch Gesture Performed by Children Under 3 Years Old when Drawing and Coloring on a Tablet. *International Journal of Human-Computer Studies*, 124:1–12, 2019.
- [17] Vicente Nacher, Javier Jaen, Elena Navarro, Alejandro Catala, and Pascual González. Multi-Touch Gestures for Pre-Kindergarten Children. *International Journal of Human-Computer Studies*, 73:37–51, 2015.
- [18] Alexis Hiniker, Kiley Sobel, Sungsoo Ray Hong, Hyewon Suh, India Irish, Daniella Kim, and Julie A Kientz. Touchscreen Prompts for Preschoolers: Designing Developmentally Appropriate Techniques for Teaching Young Children to Perform Gestures. In *Proc. International Conference on Interaction Design and Children*, 2015.
- [19] Nor Azah Abdul Aziz. Children’s Interaction with Tablet Applications: Gestures and Interface Design. *Children*, 2(3):447–450, 2013.
- [20] Celine Remi, Jean Vaillant, Rejean Plamondon, Lionel Prevost, and Theresa Duval. *Exploring the Kinematic Dimensions of Kindergarten Children’s Scribbles*. Springer, 2015.
- [21] Najmeh Behnamnia, Amirrudin Kamsin, Maizatul Akmar Binti Ismail, and A Hayati. The Effective Components of Creativity in Digital Game-Based Learning among Young Children: A Case Study. *Children and Youth Services Review*, 116:105227, 2020.
- [22] Nor Hidayah Hussain, Tengku Siti Meriam Tengku Wook, Siti Fadzilah Mat Noor, and Hazura Mohamed. Children’s Interaction Ability Towards Multi-Touch Gestures. *International Journal on Advanced Science, Engineering and Information Technology*, 6(6):875–881, 2016.
- [23] Brittany Huber, Joanne Tarasuik, Mariana N Antoniou, Chelsee Garrett, Steven J Bowe, Jordy Kaufman, and Swinburne Babylab Team. Young Children’s Transfer of Learning from a Touchscreen Device. *Computers in Human Behavior*, 56:56–64, 2016.
- [24] Ziyang Chen, Yu-Peng Chen, Alex Shaw, Aishat Aloba, Pavlo Antonenko, Jaime Ruiz, and Lisa Anthony. Examining the Link between Children’s Cognitive Development and Touchscreen Interaction Patterns. In *Proceedings of the 2020 International Conference on Multimodal Interaction*, ICMI ’20, pages 635–639, New York, NY, USA, 2020. Association for Computing Machinery.
- [25] Julia Woodward, Alex Shaw, Annie Luc, Brittany Craig, Juthika Das, Phillip Hall Jr, Akshay Holla, Germaine Irwin, Danielle Sikich, Quincy Brown, and Others. Characterizing How Interface Complexity Affects Children’s Touchscreen Interactions. In *Proc. Conference on Human Factors in Computing Systems*, 2016.

- [26] Alex Shaw and Lisa Anthony. Analyzing the Articulation Features of Children’s Touchscreen Gestures. In *Proceedings of the 18th ACM International Conference on Multimodal Interaction*, ICMI ’16, pages 333–340, New York, NY, USA, 2016. Association for Computing Machinery.
- [27] Vicente Nacher, Doris Caliz, Javier Jaen, and Loic Martinez. Examining the Usability of Touch Screen Gestures for Children with Down Syndrome. *Interacting with Computers*, 30(3):258–272, 2018.
- [28] Narges Tabatabaey-Mashadi, Rubita Sudirman, Richard M Guest, and Puspa Inayat Khalid. Analyses of Pupils’ Polygonal Shape Drawing Strategy with Respect to Handwriting Performance. *Pattern Analysis and Applications*, 18(3):571–586, 2015.
- [29] Ahmed Sabbir Arif and Cristina Sylla. A Comparative Evaluation of Touch and Pen Gestures for Adult and Child Users. In *Proceedings of the 12th International Conference on Interaction Design and Children*, IDC ’13, pages 392–395, New York, NY, USA, 2013. Association for Computing Machinery.
- [30] Patricia Laniel, Nadir Faci, Réjean Plamondon, Miriam H Beauchamp, and Bruno Gauthier. Kinematic Analysis of Fast Pen Strokes in Children with ADHD. *Applied Neuropsychology: Child*, 9(2):125–140, 2020.
- [31] C. O’Reilly and R. Plamondon. Development of a Sigma-Lognormal Representation for On-Line Signatures. *Pattern Recognition*, 42(12):3324–3337, 2009.
- [32] Seth L Pullman. Spiral Analysis: A New Technique for Measuring Tremor With a Digitizing Tablet. *Movement Disorders*, 13(S3):85–89, jan 1998.
- [33] Nobuyuki Ishii, Yuki Mochizuki, Kazutaka Shiomi, Masamitsu Nakazato, and Hitoshi Mochizuki. Spiral drawing: Quantitative analysis and artificial-intelligence-based diagnosis using a smartphone. *Journal of the Neurological Sciences*, 411:116723, 2020.
- [34] Jordi Solé-Casals, Iker Anchustegui-Echearte, Pere Marti-Puig, Pilar M Calvo, Alberto Bergareche, José Ignacio Sánchez-Méndez, and Karnele Lopez-de Ipina. Discrete Cosine Transform for the Analysis of Essential Tremor , 2019.
- [35] Po-Chieh Lin, Kai-Hsiang Chen, Bing-Shiang Yang, and Yu-Jung Chen. A digital assessment system for evaluating kinetic tremor in essential tremor and Parkinson’s disease. *BMC Neurology*, 18(1):25, 2018.
- [36] Ruben Tolosana, Ruben Vera-Rodriguez, Julian Fierrez, and Javier Ortega-Garcia. Bio-TouchPass2: Touchscreen Password Biometrics Using Time-Aligned Recurrent Neural Networks. *IEEE Transactions on Information Forensics and Security*, 15:2616–2628, 2020.
- [37] Ruben Tolosana, Ruben Vera-Rodriguez, Julian Fierrez, and Javier Ortega-Garcia. Reducing the template ageing effect in on-line signature biometrics. *IET Biometrics*, 8(6):422–430, 2019.
- [38] Ruben Tolosana, Ruben Vera-Rodriguez, Carlos Gonzalez-Garcia, Julian Fierrez, Santiago Rengifo, Aythami Morales, Javier Ortega-Garcia, Juan Carlos Ruiz-Garcia, Sergio Romero-Tapiador, Jiajia Jiang, Songxuan Lai, Lianwen Jin, Yecheng Zhu, Javier Galbally, Moises Diaz, Miguel Angel Ferrer, Marta Gomez-Barrero, Ilya Hodashinsky, Konstantin Sarin, Artem Slezkin, Marina Bardamova, Mikhail Svetlakov, Mohammad Saleem, Cintia Lia Szücs, Bence Kovari, Falk Pulsmeier, Mohamad Wehbi, Dario Zanca, Sumaiya Ahmad, Sarthak Mishra, and Suraiya Jabin. ICDAR 2021 Competition on On-Line Signature Verification. jun 2021.

- [39] Javier Hernandez-Ortega, Aythami Morales, Julian Fierrez, and Alejandro Acien. Predicting Age Groups from Touch Patterns based on Neuromotor Models. *IET Conference Proceedings*, pages 6 (6 .)–6 (6 .)(1), jan 2017.
- [40] Andreas Fischer and Réjean Plamondon. A Dissimilarity Measure for On-Line Signature Verification Based on the Sigma-Lognormal Model. In Céline Rémi, Lionel Prévost, and Eric Anquetil, editors, *17th Biennial Conference of the International Graphonomics Society*, Drawing, Handwriting Processing Analysis: New Advances and Challenges, Pointe-à-Pitre, Guadeloupe, jun 2015. International Graphonomics Society (IGS) and Université des Antilles (UA).
- [41] Réjean Plamondon, Christian O'Reilly, Céline Rémi, and Thérèse Duval. The lognormal handwriter: learning, performing, and declining. *Frontiers in Psychology*, 4:945, 2013.
- [42] Thérèse Duval, Céline Rémi, Réjean Plamondon, Jean Vaillant, and Christian O'Reilly. Combining sigma-lognormal modeling and classical features for analyzing graphomotor performances in kindergarten children. *Human Movement Science*, 43:183–200, 2015.
- [43] M Djouia and R Plamondon. A New Algorithm and System for the Characterization of Handwriting Strokes with Delta-Lognormal Parameters. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(11):2060–2072, 2009.
- [44] Hui Xu, Yangfan Zhou, and Michael R Lyu. Towards Continuous and Passive Authentication via Touch Biometrics: An Experimental Study on Smartphones. In *10th Symposium On Usable Privacy and Security (SOUPS 2014)*, pages 187–198, Menlo Park, CA, jul 2014. USENIX Association.
- [45] Rocco Zaccagnino, Carmine Capo, Alfonso Guarino, Nicola Lettieri, and Delfina Malandrino. Techno-regulation and intelligent safeguards. *Multimedia Tools and Applications*, 80(10):15803–15824, 2021.
- [46] Marcos Faundez-Zanuy, Julian Fierrez, Miguel A Ferrer, Moises Diaz, Ruben Tolosana, and Réjean Plamondon. Handwriting Biometrics: Applications and Future Trends in e-Security and e-Health. *Cognitive Computation*, 12(5):940–953, 2020.
- [47] Javier Hernandez-Ortega, Roberto Daza, Aythami Morales, Julian Fierrez, and Ruben Tolosana. Heart Rate Estimation from Face Videos for Student Assessment: Experiments on edBB. In *IEEE Conference on Computers, Software, and Applications*, 2020.
- [48] Fernando Alonso-Fernandez, Julian Fierrez-Aguilar, and Javier Ortega-Garcia. Sensor Interoperability and Fusion in Signature Verification: A Case Study Using Tablet PC. In *Proc. Int. Workshop on Biometric Recognition Systems*, 2005.
- [49] Ruben Tolosana, Ruben Vera-Rodriguez, Julian Fierrez, Aythami Morales, and Javier Ortega-Garcia. Benchmarking Desktop and Mobile Handwriting across COTS Devices: the e-BioSign Biometric Database. *PLOS ONE*, 2017.
- [50] James F Keller, James W Croake, and Carolyn Riesenman. Relationships among Handedness, Intelligence, Sex, and Reading Achievement of School Age Children. *Perceptual and Motor Skills*, 37(1):159–162, aug 1973.
- [51] Stanley Fahn, Eduardo Tolosa, and Concepcion Marin. Clinical Rating Scale for Tremor. *Parkinson's Disease and Movement Disorders*, 2:271–280, 1993.
- [52] Suleyman AL-Showarah, Naseer AL-Jawad, and Harin Sellahewa. User-Age Classification Using Touch Gestures on Smartphones. *International Journal of Multidisciplinary Studies*, 2(1):1–11, 2015.

- [53] Marcos Martinez-Diaz, Julian Fierrez, Javier Galbally, and Javier Ortega-Garcia. Towards Mobile Authentication Using Dynamic Signature Verification: Useful Features and Performance Evaluation. In *Proc. Int. Conf. on Pattern Recognition*, 2008.
- [54] Marcos Martinez-Diaz, Julian Fierrez and S. Hangai. Signature Features. *S.Z. Li and A. Jain (Eds.), Encyclopedia of Biometrics*, Springer, pages 1375–1382, 2015.
- [55] Ruben Tolosana, Ruben Vera-Rodriguez, Julian Fierrez, and Javier Ortega-Garcia. Feature-based dynamic signature verification under forensic scenarios. In *3rd International Workshop on Biometrics and Forensics (IWBF 2015)*, pages 1–6, 2015.
- [56] Ronald Aylmer Fisher. The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, 7(2):179–188, sep 1936.
- [57] Ruben Tolosana, Ruben Vera-Rodriguez, Javier Ortega-Garcia, and Julian Fierrez. Pre-processing and Feature Selection for Improved Sensor Interoperability in Online Biometric Signature Verification. *IEEE Access*, 3:478–489, 2015.
- [58] Javier Galbally, Julian Fierrez, Manuel Ricardo Freire, and Javier Ortega-Garcia. Feature Selection based on Genetic Algorithms for On-Line Signature Verification. In *Proc. IEEE Workshop on Automatic Identification Advanced Technologies, AutoID*, 2007.
- [59] David E Goldberg. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Longman Publishing Co., Inc., USA, 1st edition, 1989.
- [60] Trevor Hastie, Saharon Rosset, Ji Zhu, and Hui Zou. Multi-Class AdaBoost. *Statistics and Its Interface*, 2(3):349–360, 2009.
- [61] Leland McInnes, John Healy, and James Melville. UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction. feb 2018.
- [62] David Michalec. Bayley Scales of Infant Development: Third Edition BT - Encyclopedia of Child Behavior and Development. page 215. Springer US, Boston, MA, 2011.
- [63] Laura Shank. Mullen Scales of Early Learning BT - Encyclopedia of Clinical Neuropsychology. pages 1669–1671. Springer New York, New York, NY, 2011.
- [64] Ruben Tolosana, Paula Delgado-Santos, Andres Perez-Urbe, Ruben Vera-Rodriguez, Julian Fierrez, and Aythami Morales. DeepWriteSYN: On-Line Handwriting Synthesis via Deep Short-Term Representations. In *Proc. 35th AAAI Conference on Artificial Intelligence*, 2021.
- [65] Ruben Tolosana, Ruben Vera-Rodriguez, Julian Fierrez, and Javier Ortega-Garcia. Deep-Sign: Deep On-Line Signature Verification. *IEEE Transactions on Biometrics, Behavior, and Identity Science*, 3(2):229–239, 2021.
- [66] Julian Fierrez-Aguilar, Daniel Garcia-Romero, Javier Ortega-Garcia, and Joaquin Gonzalez-Rodriguez. Adapted user-dependent multimodal biometric authentication exploiting general information. *Pattern Recognition Letters*, 26(16):2628–2639, 2005.
- [67] Christina T Fuentes, Stewart H Mostofsky, and Amy J Bastian. Children with Autism Show Specific Handwriting Impairments. *Neurology*, 73(19):1532–1537, 2009.
- [68] Julian Fierrez, Aythami Morales, Ruben Vera-Rodriguez, and David Camacho. Multiple Classifiers in Biometrics. Part 1: Fundamentals and Review. *Information Fusion*, 44:57–64, 2018.

- [69] R. Castrillon, Alejandro Acien, Juan Rafael Orozco-Arroyave, Aythami Morales, JF Vargas, Ruben Vera-Rodriguez, Julian Fierrez, Javier Ortega-Garcia, and A. Villegas. Characterization of the Handwriting Skills as a Biomarker for Parkinson Disease, 2019.